

Optimierung der Energiebilanzen im Microgrid

Carola Gerwig

im Microgrid
Optimierung der Energiebilanzen
Optimierung der
Energiebilanzen im Mi
Microgrid
Optimierung

Carola Gerwig

Optimierung der Energiebilanzen im Microgrid

UV Universitätsverlag
Hildesheim

Hildesheim 2017

Optimierung der Energiebilanzen im Microgrid

Carola Gerwig

Dissertation

zur Erlangung des akademischen Grades

Dr. rer. nat.

im Bereich der Umweltwissenschaften

an der Stiftung Universität Hildesheim

Fachbereich 4 Mathematik, Naturwissenschaften, Wirtschaft und Informatik

Gutachter

Gutachter 1: Helmut Lessing, Stiftung Universität Hildesheim

Gutachter 2: Hans-Jörg von Mettenheim, Gottfried Wilhelm Leibniz Universität Hannover

Tag der Disputation: 12. Juni 2017

Impressum

Die Deutsche Nationalbibliothek verzeichnet diese Publikation in der Deutschen Nationalbibliografie; detaillierte bibliografische Daten sind im Internet über <http://dnb.d-nb.de> abrufbar.

Diese elektronische Publikation ist mit der Creative-Commons-Nutzungslizenz BY-NC-ND (Namensnennung – Nicht kommerziell – Keine Bearbeitung) versehen.

Weitere Informationen unter: <http://creativecommons.org/licenses/by-nc-nd/3.0/de>

Universitätsverlag Hildesheim
Universitätsplatz 1
31141 Hildesheim

www.uni-hildesheim.de/bibliothek/publizieren/open-access-universitaetsverlag

Erstausgabe Hildesheim 2017
<http://dx.doi.org/10.18442/695>

Zitierempfehlung:

Gerwig, Carola (2017). *Optimierung der Energiebilanzen im Microgrid*.
Hildesheim: Universitätsverlag Hildesheim. E-Publikation (Open Access): <http://dx.doi.org/10.18442/695>

*„Die Mehrkosten für erneuerbare Energien von heute sind gesicherte Energie,
vermiedene Umweltschäden und niedrige Energiekosten von morgen.“*


– Hermann Scheer

(1944-2010) deutscher Politiker, Träger des alternativen Nobelpreises

Abstract

Die Reduktion der Treibhausgasemissionen gehört zu den maßgeblichen Zielen, welche mit der Neuausrichtung der Energienetze hin zu erneuerbaren Energien verfolgt werden. Vor diesem Hintergrund bedarf es geeigneter Modelle und Methoden, mit welchen dezentrale, erneuerbare Energieanlagen in die Energienetze eingebunden und effizient genutzt werden können. Die vorliegende Arbeit stellt dar, wie durch die Vernetzung von lokalen Energieerzeugern und Verbrauchern zu Microgrids eine umweltfreundliche Energieversorgung vor Ort gestaltet werden kann und quantifiziert das Potential dieses Konzepts.

Dazu wird nach Methoden gesucht, mit welchen auf lokaler Ebene ein Ausgleich von Energieerzeugung und Nachfrage umgesetzt werden kann. Auf Erzeugerseite wird eine koordinierte, vorausschauende Betriebsführung für die Kombination eines Mikro-Blockheizkraftwerks mit Photovoltaikanlagen entwickelt. In der Simulation werden die Kohlenstoffdioxidemissionen der Strom- und Wärmeversorgung somit um 33% gesenkt. Zur Optimierung auf Verbraucherseite werden Methoden zur Lastverschiebung (Demand Side Management) von Haushaltsgeräten evaluiert. Die Simulation zeigt, dass das Potential zur Senkung der Emissionen auf Verbraucherseite zwar geringer ist, aber bei der Konzeption entsprechender Stromtarife die Energienetze durch die Nutzung von Demand Side Management durchaus entlastet werden können. Ergänzt werden die Optimierungsmethoden durch eine umfassende Analyse von kurzfristigen Stromlastprognosen auf Verbraucherebene, da diese Prognosen für die nachgelagerten Optimierungsverfahren benötigt werden. Diese Analyse gibt Aufschluss über geeignete Methoden und die erwartbaren Prognosefehler.



Abstract in English


The climate change is linked to the emission of greenhouse gases, of which a material proportion results from the provision of energy. These emissions have to be reduced significantly in order to mitigate the effects of the global warming. The increasing installation of distributed energy resources and the digitalization of energy systems constitute both challenges and opportunities to contribute to a sustainable energy supply. The present work shows ways to reduce carbon emissions by optimizing the local energy balances of microgrids.

Therefore, a microgrid consisting of a small number of households and distributed energy sources is designed and methods for the local coordination of the components are developed. A novel predictive operation strategy of a micro combined power and heat unit (CHP) in combination with solar plants is proposed. The results of the simulations point out that a great amount of the energy demand can be produced locally. This implies great savings in carbon emissions and low operational costs.

Further, optimization methods are implemented which shift deferrable loads in times which are favorable for the energy networks. This approach is called demand side management (DSM). The simulations reveal that the potential to reduce the carbon emissions on the consumption side is not as high as on the generation side. Nevertheless, DSM in households can contribute to the local electricity network stability.

The local optimization strategies are based on short term load forecasts of the residential loads. Therefore, a comprehensive analysis of forecasting methods is conducted. The analysis provides information about suitable methods and the expected forecasting errors.

The development of the optimization methods and the evaluation on the simulated microgrids show the great potential that lies in the optimization of a local energy system.



Management Summary

Ausgangssituation

Vor dem Hintergrund der globalen Erderwärmung besteht unter den Klimaforschern weltweit breiter Konsens über die Notwendigkeit, die Emissionen von Treibhausgasen deutlich zu reduzieren, um die Auswirkungen des Klimawandels abzumildern. Entsprechende Ziele wurden auf europäischer sowie weltweiter Ebene formuliert.

In Deutschland wurde der Ausbau regenerativer Energien im Energiesektor bereits erfolgreich gefördert. Da die Stromerzeugung aus regenerativen Energien jedoch von schlecht beeinflussbaren Größen wie dem Bewölkungsgrad oder der Windstärke abhängt, ist der Ausbau mit einem zunehmend volatilen Stromangebot verbunden. Dies stellt die Energieversorgungssysteme vor neue Herausforderungen. Denn übersteigt die Stromerzeugung die Nachfrage, so müssen Kraftwerke abgeregelt werden, wird kaum Strom mittels erneuerbarer Energieanlagen erzeugt, muss die Nachfrage durch den teuren Betrieb von Spitzenlastkraftwerken gedeckt werden.

Nach einer aktuellen Studie des VDE (Verband der Elektrotechnik Elektronik Informationstechnik e.V.) von 2015 [1] wird die Grundlage für eine nachhaltige Entwicklung der Energieversorgung in einem zellularen Ansatz gesehen, in welchem ein Ausgleich von Erzeugung und Last bereits auf der niedrigsten möglichen Ebene erfolgen soll. Ein lokaler Verbund von Energieerzeugern, Verbrauchern und Speichereinheiten, welcher in koordinierter Weise betrieben werden kann, wird als Microgrid bezeichnet. Vorteile von Microgrids liegen darin, dass kaum Netzverluste anfallen und zudem kleine Kraft-Wärme-Kopplungsanlagen (KWK-Anlagen) wie Blockheizkraftwerke (BHKW) betrieben werden können, bei denen die Abwärme lokal genutzt werden kann.

Ziele und Vorgehen der Arbeit

In dieser Dissertation soll dargelegt werden, welche Methoden sich für die Optimierung der Energiebilanzen im Microgrid eignen. Dabei richtet sich der Fokus auf drei Aspekte:

- (1) **Optimierung der lokalen Energieerzeugung** im Microgrid,
- (2) **Optimierung der Nachfrage** durch Demand Side Management DSM,
- (3) **Analyse von kurzfristigen Stromlastprognosen für Wohngebäude.**

Zu (1): Zur Optimierung der lokalen Energieerzeugung wird ein Microgrid konzipiert, in welches ein Mikro-BHKW und Photovoltaikanlagen (PV-Anlagen) als lokale Stromerzeuger eingebunden sind. Die Kombination dieser Einheiten bietet ein Optimierungspotential, welches in der Forschung bisher vernachlässigt wurde. Aufgrund der simultanen Erzeugung von Strom und Wärme ist ein Mikro-BHKW äußerst effizient und umweltfreundlich, wenn sichergestellt werden kann, dass sowohl der erzeugte Strom als auch die erzeugte Wärme lokal genutzt werden. PV-Anlagen

stellen hingegen hauptsächlich in der warmen Jahreszeit Strom bereit, wenn weniger Heizbedarf besteht. Um die Vorteile einer solchen Kombination auszuschöpfen, wird eine vorausschauende und koordinative Steuerung eines Mikro-BHKWs unter Berücksichtigung der anderen Komponenten im Microgrid entwickelt. Validiert wird der Ansatz auf simulierten Microgrids mit unterschiedlichen Ausstattungen. Eine Robustheitsanalyse gibt Aufschluss darüber, wie stabil die Ergebnisse bei zufälligen Fehlern in den Prognosen des Strombedarfs und der Solarstromerzeugung sind.

Zu (2): Zur Optimierung des lokalen Strombezugs werden geeignete DSM-Verfahren zur automatisierten Verschiebung von Haushaltslasten identifiziert, implementiert und ausgewertet. Durch die Lastverschiebungen kann entweder der lokale Strombezug geglättet oder der Strombezug in Zeiten geschoben werden, in welchen in den übergeordneten Stromnetzen überdurchschnittlich viel Strom aus erneuerbaren Energien verfügbar ist und der Strommix einen besonders niedrigen Emissionsfaktor aufweist. Die beiden Zielsetzungen werden separat untersucht. Zur Umsetzung werden zwei Ansätze aus der Literatur ausgewählt:

- individuelles DSM, bei welchem in jedem Haushalt die Lastverschiebungen unabhängig von dem Verbrauch anderer Haushalten optimiert wird,
- koordinatives DSM nach dem Konzept von Mohsenian-Rad [2], bei welchem mittels eines Multi-Agenten-Systems zwischen den Haushalten im Verbund über die Lastverschiebungen verhandelt wird.

Die Methoden werden für die Anwendung im Microgrid angepasst. Dabei werden die Lasten von Großverbrauchern wie Spül- und Waschmaschinen sowie Trocknern als diejenigen identifiziert, welche in Haushalten typischerweise verschoben werden können. Auf Basis von Simulationen auf realen Haushaltsdaten werden die Potentiale der beiden Ansätze unter verschiedenen Annahmen quantifiziert.

Zu (3): Zur Analyse der kurzfristigen Stromlastprognosen wird zunächst ein umfassender Literaturreview nach dem Konzept von vom Brocke [3] vorgenommen. Im Anschluss werden eigene, umfangreiche Experimente zur Analyse der Prognosegüte durchgeführt. Dafür werden sieben State-of-the-Art Verfahren aus dem Bereich der statistischen Zeitreihenanalyse und der künstlichen Intelligenz implementiert und auf 165 Datenreihen evaluiert. Die erreichten Prognosegenauigkeiten werden im Hinblick auf Skalierungseffekte, Prognosehorizont und Input-Variablen analysiert.

Die Auswertung erfolgt bei jedem der drei Aspekte auf Basis realer Daten aus allgemein verfügbaren Datensätzen, was die Ergebnisse vergleichbar und reproduzierbar macht. Bei den Optimierungsverfahren wird ein besonderer Fokus gelegt auf

- die Reduktion der Kohlenstoffdioxidemissionen (CO₂-Emissionen),
- die Senkung der Betriebskosten und
- die Entlastung der übergeordneten Stromnetze.

Ergebnisse

Zu (1): In der Simulation konnte durch die lokale Stromerzeugung bereits 85% des Bedarfs vor Ort gedeckt werden. Dabei betrug der Anteil der lokalen Stromversorgung in jedem Monat mindestens 74%. Die CO₂-Emissionen wurden in diesem Ansatz um 65%, bezogen auf die Stromversorgung, und um 33%, bezogen auf die gesamte Energieversorgung, reduziert. Durch einen Umstieg von Erdgas auf Biogas können weitere Einsparungen erreicht werden. Die Ergebnisse erwiesen sich als robust gegenüber den modellierten Prognosefehlern.

Die Vorteile des Konzepts zeigen sich auch in der Auswertung der Betriebskosten. In der Simulation wurde eine Reduktion der laufenden Energiekosten um bis zu 45% erreicht. Zudem wurde der Netzbezug deutlich reduziert und die täglichen Spitzenlasten durchschnittlich um 68% gesenkt. Bei zeitvariablen Strompreisen wurde der verbleibende Strombezug in Zeiten verlagert, in welchen ein günstiger Strompreis vorlag. In diesem Sinne trägt der Ansatz neben der Reduktion der CO₂-Emissionen auch zu ausgeglicheneren Stromnetzen bei.

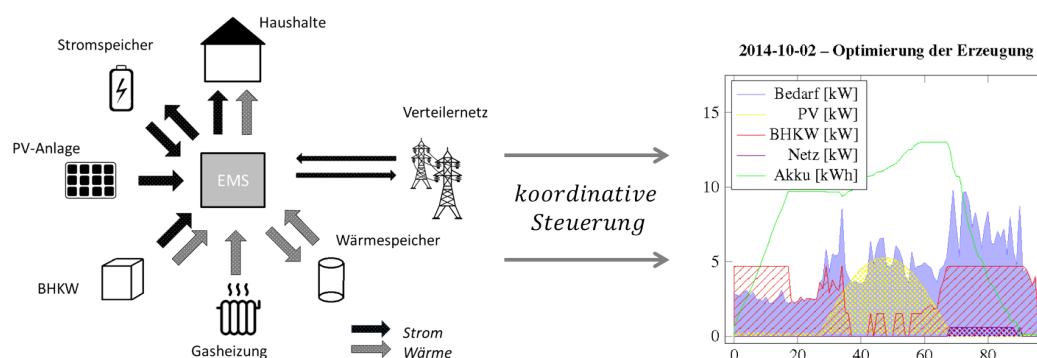


Abbildung 1: Optimierung der Erzeugung; links ist die Konzeption des Microgrids und rechts die optimierten Energiebilanzen für einen Tag der Simulation dargestellt. Der Strombedarf wird nahezu vollständig durch die PV-Anlage und Mikro-BHKW gedeckt. Dabei ist gewährleistet, dass die Wärmeproduktion des BHKWs den Tagesbedarf an Wärme nicht überschreitet.

Zu (2): Bei den verwendeten Verbrauchsdaten waren ca. 10% der Stromlasten verschiebbar. Der durchschnittliche Anteil der verschiebbaren Lasten an den Spitzenlasten betrug ebenfalls 10%. In der Simulation wurde durch den koordinativen Ansatz bereits bei Lastverschiebungen von maximal einer Stunde eine durchschnittliche Spitzenlastreduktion von 8% erreicht. Mit individuellem DSM wurde für dasselbe Setting eine Spitzenlastreduktion von 2% erreicht. Nur für eine Lastverschiebungstoleranz von 24 Stunden konnte bei individuellem DSM mit 9% eine vergleichbare Spitzenlastreduktion erreicht werden.

Im Hinblick auf die CO₂-Emissionen tragen die DSM-Verfahren zu einer Erhö-

hung des Eigenverbrauchs bei, wenn eine PV-Anlage installiert ist. Bei einem DSM mit der Zielsetzung den Strombedarf zu glätten, wurden die CO₂-Emissionen damit in der Simulation um bis zu 3% gesenkt. Bei der Anpassung der Lasten an Vorgaben der übergeordneten Netze in Form von zeitvariablen Stromtarifen wurden eine Reduktion von bis zu 7% erreicht.




Abbildung 2: Optimierung der Nachfrage mittels DSM-Verfahren. Links ist der verschobene Strombezug für einen Tag der Simulation bei der Zielsetzung, diesen zu glätten, dargestellt. Die verschiebbaren Lasten werden in die Mittagszeit geschoben. Rechts werden die verschiebbaren Lasten gemäß übergeordneter Vorgaben in Form von zeitvariablen Strompreisen verschoben. Dabei entsteht ein Peak am frühen Morgen, wenn der Strompreis am niedrigsten ist.

Zu (3): Der Literaturreview nach dem Konzept von vom Brocke offenbart die Defizite der bisherigen Analysen in diesem Bereich. So waren die Ergebnisse des Literaturreviews teilweise widersprüchlich und konnten aufgrund der Verwendung von projekt-internen Datensätzen nicht reproduziert werden.

In den Experimenten führte die lineare Regression in den meisten Settings zu den kleinsten Prognosefehlern und scheint damit eine einfache und erfolgreiche Methode zur Erstellung von kurzfristigen Stromlastprognosen zu sein. Unter der Verwendung bestimmter Kennzahlen zur Bewertung der Prognosegüte erzielte die nächste-Nachbarn-Regression kompetitive Ergebnisse. Andere Methoden wiesen nur für einzelne Settings vergleichbare oder bessere Ergebnisse auf.

Die durchschnittlichen Prognosefehler nahmen bei einem steigenden Aggregationsgrad ab. Es wurde in einer Regressionsanalyse gezeigt, dass ein starker Zusammenhang zwischen dem Variationskoeffizienten einer Verbrauchsdatenreihe und der Prognosegüte besteht. Dieser lässt sich durch eine logarithmische Funktion abschätzen. Entsprechend führte ein steigender Prognosehorizont zunächst zu einem

deutlich wachsenden Prognosefehler, während für einen Prognosehorizont größer vier Stunden die Fehler nur noch marginal wuchsen. Die durchschnittlichen Prognosefehler einzelner Haushalte lagen für Prognosen eine halbe Stunde im Voraus zwischen 33% und 55%. Sie nahmen jedoch bei steigendem Aggregationsgrad stark ab. Bei einem Zusammenschluss von 10 Haushalten halbierten sich die durchschnittlichen Fehler in den Experimenten.

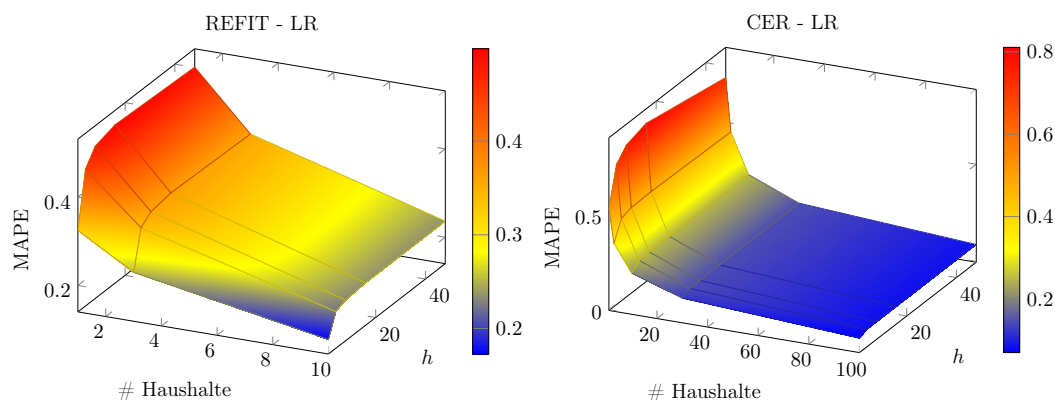


Abbildung 3: Darstellung des Mean Absolute Percentage Error (MAPE) von kurzfristigen Stromlastprognosen mittels linearer Regression (LR) bei verschiedenen Aggregationsgraden (# Anzahl der Haushalte) und Prognosehorizonten h für zwei öffentlich verfügbare Datensätze, REFIT und CER.

Bewertung und Handlungsempfehlungen

Im direkten Vergleich der angewandten Optimierungsverfahren wird deutlich, dass das Potential zur Reduktion der CO₂-Emissionen und der Reduktion der Spitzenlasten auf der Erzeugerseite **wesentlich** höher ist als auf der Verbraucherseite.

Zu (1): Nach den Ergebnissen der Simulation würde bei vollständigem Ausschöpfen des Optimierungspotentials und der Verwendung von Biogas nur noch **ein Fünftel der CO₂-Emissionen** im Vergleich zu einer konventionellen Energieversorgung verursacht werden. Dieses Ergebnis ist zwar unter gewissen Limitierungen (vgl. Abschnitt 2.6.1) zu betrachten, zeigt aber das erhebliche Potential hinsichtlich der Erreichung der Klimaziele.

Zu den positiven Effekten der Optimierung auf Erzeugerseite tragen insbesondere drei konzeptionelle Maßnahmen bei:

- die gemeinsame Betrachtung der Strom- und Wärmeversorgung,
- die Nutzung von KWK in Kombination mit PV-Anlagen,
- die koordinierte, prädiktive Steuerung der Komponenten.

Die gemeinsame Nutzung und die koordinierte Steuerung der KWK- und PV-Anlage steigert die Gesamtwirtschaftlichkeit durch eine höhere Rentabilität der Anlagen. Aufgrund des Zusammenschlusses wird zum einen der Eigenverbrauch des Solarstroms erhöht und zum anderen ein erhöhter Auslastungsgrad des BHKWs bei ausschließlich lokaler Nutzung des erzeugten BHKW-Stroms erreicht.

Zu (2): Im Vergleich zu dem Potential, welches sich auf der Erzeugerseite offenbart, wirken die durch die Lastverschiebungen auf Verbraucherseite erzielten Effekte eher gering. Allerdings sollten diese nicht als Konkurrenz, sondern als zusätzliche Option der Optimierung betrachtet werden. Auch die verschiedenen Ansätze, welche für die Umsetzung von DSM evaluiert wurden, müssen nicht in direkter Konkurrenz stehen. So lässt sich das individuelle DSM ohne Microgridstruktur umsetzen und kann bereits heute in entsprechend ausgestatteten Haushalten realisiert werden. Für einen flächendeckenden Einsatz empfiehlt sich der koordinative Ansatz, da somit mögliche negative Rückkopplungseffekte vermieden werden und zudem die Effekte bereits bei geringer zeitlicher Flexibilität deutlich höher sind.

Mit dem eingeleiteten Rollout von Smart Metern wird die Grundlage für die notwendige Kommunikationsinfrastruktur zur Umsetzung von DSM geschaffen. Darüber hinaus bedarf es finanzieller Anreizsysteme, welche den Verbraucher zur Nutzung von DSM motivieren:

- Die finanzielle Förderung von haushaltsinternen Energiemanagementsystemen und programmierbarer Haushaltsgeräte könnte die Verbreitung von DSM beschleunigen.
- Die Umsetzung geeigneter zeitvariabler Stromtarife wäre ein monetärer Anreiz für den Endverbraucher, ein Energiemanagementsystem zu nutzen und sich auf DSM einzulassen.
- Alternativ könnten Boni für Kunden eingeführt werden, welche ein Energiemanagement mit DSM nutzen. Die Höhe der Boni sollte dabei von der Menge des flexiblen Strombedarfs und der Flexibilität dieses Bedarfs abhängen.

Zu (3): Für die Anwendung der kurzfristigen Stromlastprognosen ist die lineare Regression ein universell gut funktionierendes Verfahren. Es empfiehlt sich stets, die Stromlasten mehrerer Haushalte gemeinsam zu betrachten. In den Experimenten konnten für einzelne Haushalte aufgrund der hohen Variabilität im Stromverbrauch keine verlässlichen Prognosen erzielt werden. Der **Zusammenschluss zu einem Microgrid** ist ein erfolgversprechender Ansatz, diesem Problem zu begegnen. Da die Prognosefehler bei steigendem Prognosehorizont ansteigen, erscheint es zudem ratsam, in der nachfolgenden Optimierung regelmäßige Updates vorzusehen, in welche aktualisierte Prognosen eingehen. Anhand der aufgestellten Regressionskurven für die Prognosefehler kann die Prognosegüte im Vorfeld abgeschätzt werden.

Danksagungen

Ich möchte mich zuallererst bei meinem Doktorvater Herrn Prof. Dr. Helmut Lessing bedanken. Auf seine Vorstellung einer emissionsfreien Energieversorgung geht die Wahl des Dissertationsthemas zurück. Danke für die fortwährende Unterstützung meines Promotionsvorhabens.

Ich möchte mich weiterhin meinem Zweitbetreuer Herrn Prof. Dr. Hans-Jörg von Mettenheim für seine wertvollen Anregungen bedanken. Er hat mir viele Denkanstöße für die Durchführung und Auswertung der Arbeit gegeben.

Zudem möchte ich Herrn Prof. Lars Schmidt-Thieme meinen Dank dafür aussprechen, dass ich an den Forschungsaktivitäten seiner Arbeitsgruppe teilnehmen und dabei mein Wissen über maschinelles Lernen ausbauen konnte.

Darüber hinaus haben mich viele weitere Personen auf dem Weg der Promotion begleitet. Allen Kollegen an der Universität möchte ich für eine konstruktive Zusammenarbeit, interessante Gespräche sowie eine gute Zeit danken.

Ein besonderer Dank sei an dieser Stelle meinen Eltern Ingeborg und Günter Gerwig ausgesprochen, die stets für mich da sind und die vorliegende Arbeit auf formale Fehler geprüft haben.

Mein größter Dank aber gilt Tim Eickmann, der nicht nur jedes Kapitel akribisch Korrektur gelesen hat, sondern der mich während des gesamten Promotionsvorhabens motiviert und mir insbesondere in stressigen Zeiten Rückhalt gegeben hat.

Inhaltsverzeichnis

Abstract	ii
Abstract in English	iii
Management Summary	iv
Abkürzungsverzeichnis	xiv
Symbolverzeichnis	xvi
Abbildungsverzeichnis	xx
Tabellenverzeichnis	xxii
1 Smart Energy made in Microgrids	1
1.1 Hintergrund	1
1.2 Ziele der Arbeit	3
1.3 Vorgehensweise	4
2 Optimierung eines Mikro-BHKWs im Microgrid	6
2.1 Ansatz	7
2.2 Grundlagen und verwandte Arbeiten	9
2.2.1 Variable Strompreise	10
2.2.2 Betriebsführung von BHKW	11
2.2.3 Abgrenzung des eigenen Forschungsansatzes	13
2.3 Modellierung	14
2.3.1 Gesamtkonzeption des Microgrids	14
2.3.2 Modellierung der Komponenten	14
2.3.3 Modellierung der CO ₂ -Emissionen	16
2.3.4 Modellierung der Betriebskosten	18
2.3.5 Optimierungsproblem	20
2.3.6 Betriebsmodus	21
2.4 Simulation	30
2.4.1 Spezifikation der Komponenten	30
2.4.2 Spezifikation der Betriebskosten	31
2.4.3 Spezifikation der Kennzahlen	32
2.4.4 Aufbau der Robustheitsanalyse	34
2.5 Ergebnisse der Simulation	35
2.5.1 Energiebilanzen	36
2.5.2 Ökobilanzen	40
2.5.3 Analyse der Betriebskosten	41

Inhaltsverzeichnis

2.5.4	Reduktion der Spitzenlasten	43
2.5.5	Robustheitsanalyse	44
2.6	Diskussion	45
2.6.1	Einschränkende Faktoren	45
2.6.2	Weitergehende Forschungsfragen	46
2.7	Zusammenfassung	47
3	Optimierung des Stromverbrauchs durch DSM	49
3.1	Ansatz	50
3.2	Grundlagen und verwandte Arbeiten	51
3.2.1	DSM-Verfahren einzelner Haushalte	52
3.2.2	Koordinative DSM-Verfahren	53
3.2.3	Förderung von DSM in Deutschland	56
3.2.4	Gewählte Ansätze für die Modellierung	57
3.3	Modellierung	58
3.3.1	Modellierung der Komponenten	58
3.3.2	Modellierung der Stromtarife	60
3.3.3	Modellierung der CO ₂ -Emissionen	60
3.3.4	Optimierungsziele	61
3.3.5	Umsetzung der DSM-Verfahren	62
3.3.6	Konvergenzverhalten gegen globales Optimum	64
3.4	Simulation	66
3.4.1	Spezifikation der Komponenten	66
3.4.2	Spezifikation der Stromtarife	67
3.4.3	Spezifikation der CO ₂ -Emissionsfaktoren	68
3.4.4	Kennzahlen	68
3.5	Ergebnisse der Simulation	69
3.5.1	Energiebilanzen	69
3.5.2	Glättung des Strombezugs	71
3.5.3	Reduktion der Stromkosten	73
3.5.4	Reduktion der CO ₂ -Emissionen	74
3.6	Diskussion	76
3.6.1	Zielsetzung von DSM	76
3.6.2	Konzeption der Stromtarife	77
3.6.3	Unsicherheiten in der Optimierung	78
3.6.4	Kommunikationsinfrastruktur und Datensicherheit	78
3.6.5	Flexibilität und weiteres Potenzial	79
3.7	Zusammenfassung	79
4	Kurzfristige Stromlastprognosen für Wohngebäude	81
4.1	Ansatz	82
4.2	Literaturreview	83
4.2.1	Bestimmung des Review-Fokus	83
4.2.2	Konzeptualisierung	84

Inhaltsverzeichnis

4.2.3	Literatursuche	86
4.2.4	Methodenübersicht	87
4.2.5	Analyse und Synthese	94
4.2.6	Zusammenfassung und Schlussfolgerungen	98
4.3	Experimente	100
4.3.1	Daten	101
4.3.2	Trainings- und Testmengen	106
4.3.3	Methoden	106
4.3.4	Input-Variablen	117
4.3.5	Kennzahlen	119
4.4	Ergebnisse und Auswertung	120
4.4.1	Gesamtübersicht	120
4.4.2	Vergleich der Methoden	120
4.4.3	Skalierungseffekte	125
4.4.4	Prognosezeitraum	127
4.4.5	Analyse der Input-Variablen	129
4.5	Diskussion	132
4.5.1	Limitierungen	133
4.5.2	Weitergehende Forschungsfragen	133
4.6	Zusammenfassung	134
5	Zusammenfassung und Ausblick	136
5.1	Zusammenfassung der Arbeit	136
5.2	Abschließende Bewertung der Optimierungsansätze	139
5.3	Forschungsbedarf und Ausblick	140
A	Appendix	142
A.1	Ergebnisse der ADF-Tests	142
	Literaturverzeichnis	146

Abkürzungsverzeichnis

ADF-Test	Augmented Dickey-Fuller-Test.
AG	Auslastungsgrad.
ANN	Artificial Neuronal Network.
AR	Autoregressives Modell.
AR⁺	Additives Autoregressives Modell.
ARIMA	Autoregressives Integriertes Moving Average-Modell.
ARMA	Autoregressives Moving Average-Modell.
BAFA	Bundesamt für Wirtschaft und Ausfuhrkontrolle.
BDEW	Bundesverband der Energie- und Wasserwirtschaft.
BHKW	Blockheizkraftwerk.
BMWi	Bundesministerium für Wirtschaft und Technologie.
CIGRÉ	Conseil International des Grands Réseaux Électriques.
CO₂	Kohlenstoffdioxid.
ct	Eurocent.
DSM	Demand Side Management.
EEG	Erneuerbare-Energien-Gesetz.
EEX	European Energy Exchange.
EPEX SPOT SE	Power spot market of European Energy Exchange.
ES	Exponentielle Glättung.
FIT	Feed-in Tarif.
GW	Gigawatt.
HVAC	Heating, Ventilation and Air Conditioning.
IKT	Informations- und Kommunikationstechnologien.
KF	Kalman Filter.
KNN	K-Nächste-Nachbarn-Regression.
kW	Kilo Watt.
kWh	Kilo Wattstunde.
KWK	Kraft-Wärme-Kopplung.
KWKG	Kraft-Wärme-Kopplungsgesetz.
kWp	KiloWatt Peak.

LR	lineare Regression.
MA	Moving Average.
MAPE	Mean Average Percentage Error.
MKWI	Multikonferenz Wirtschaftsinformatik.
moma	Modellstadt Mannheim.
NMAE	Normalized Mean Average Error.
NMRSE	Normalized Root Mean Squared Error.
OGEMA	Open Gateway Energy Management.
PACF	partielle Autokorrelationfunktion.
PAR	Peak-to-Average Ratio.
PAR_d	durchschnittliche tägliche Peak-to-Average Ratio.
PER	Persistente Prognose.
PR	Peak Reduction – Spitzenlastreduktion.
PR_d	durchschnittliche tägliche Spitzenlastreduktion.
PV	Photovoltaik.
PVGIS	Photovoltaik Geographical Information System.
RB	Regressionsbaum.
REDD	Reference Energy Disaggregation Dataset.
REFIT	REFIT: Personalised Retrofit Decision Support Tools for UK Homes using Smart Home Technology project.
RF	Random Forest.
RMSE	Root Mean Squared Error.
RTP	Real-Time-Pricing.
SAR	Saisonales Autoregressives Modell.
SOFC	Festoxidbrennstoffzelle (Solid Oxide Fuel Cell).
STLF	Short-Term Load Forecasting.
SVM	Support Vector Machines.
SVR	Support Vector Regression.
TOU	Time-of-Use Pricing.
VDE	Verband der Elektrotechnik Elektronik Informationstechnik e.V..
VDI	Verein Deutscher Ingenieure.

Symbolverzeichnis

$ $	„mit der Eigenschaft“.
\exists	„es existiert“.
\forall	„für alle“.
\in	„ist Element von“.
\subset	„ist eine Teilmenge von“.
$:=$	„ist definiert durch“.
$\langle \cdot; \cdot \rangle$	Skalarprodukt im euklidischen Raum.
$\mathbb{E}[X]$	Erwartungswert einer Zufallsvariablen X .
$\mathcal{N}(\mu; \sigma^2)$	Normalverteilung mit Erwartungswert μ und Varianz σ^2 .
\mathbb{N}	Menge der natürlichen Zahlen inklusive 0.
p -Wert	Überschreitungswahrscheinlichkeit.
\mathbb{R}^k	Menge der k -dimensionalen reellen Vektoren.
\mathbb{R}^+	Menge der nichtnegativen reellen Zahlen.
\mathbb{R}	Menge der reellen Zahlen.
sgn	Vorzeichenfunktion signum.
τ_{ADF}	ADF-Teststatistik.
$[\alpha_{n,a}; \beta_{n,a}]$	Zeitintervall, in welchem die verschiebbare Last des Verbrauchers a der Wohnung n ausgeführt werden soll.
$\delta_{n,a}$	Länge eines festen Lastprofils $\bar{\mathbf{y}}_{n_a}$ in Viertelstunden.
$\varepsilon_{n,a}$	$\delta_{n,a} - 1$.
φ_b	Stromkennzahl des Mikro-BHKWs.
η_a	Wirkungsgrad des Stromspeichers.
η_b	Wirkungsgrad des Mikro-BHKWs.
A_{HT}	Strombezug in Hochlastenzeiten im Verhältnis zum Gesamtbedarf.
A_{NT}	Strombezug in Niederlastenzeiten im Verhältnis zum Gesamtbedarf.
A_{BHKW}	Stromproduktion des Mikro-BHKWs im Verhältnis zum Gesamtbedarf.
A_{FIT}	Eingespeiste Strommenge im Verhältnis zum Gesamtbedarf.
A_{Netz}	Strombezug aus dem Verteilernetz im Verhältnis zum Gesamtbedarf.
A_{PV}	Stromproduktion des PV-Anlage im Verhältnis zum Gesamtbedarf.
\mathcal{A}_n	Menge der Verbraucher in einem Haushalt n .
a_{max}	Kapazität des Stromspeichers in kWh.
a_t	Zustand des Stromspeichers zu Beginn eines Zeitintervall t in kWh.
ϕ_{AG}	durchschnittlicher Auslastungsgrad.
b_{max}	Maximale Menge an Strom in kWh, welche das Mikro-BHKW in einem Zeitintervall t bereitstellen kann.
b_{min}	Minimale Menge an Strom in kWh, welche das Mikro-BHKW in einem Zeitintervall t bereitstellen kann, ohne ausgeschaltet zu werden.

b_t	Stromerzeugung des Mikro-BHKWs im Zeitintervall t in kWh.
b_t^*	optimale Stromerzeugung des Mikro-BHKWs im Zeitintervall t in kWh.
\tilde{b}_t	Betriebsführung des Mikro-BHKWs zum Zeitpunkt \tilde{t} in kW.
c_b	Brennstoffkosten bei Betrieb des Mikro-BHKWs [ct/kWh].
c_f	Einspeisevergütung [ct/kWh].
c_p	fester Strompreis für Strombezug aus Verteilernetz [ct/kWh].
$c_{p,t}$	Strompreis für Strombezug aus Verteilernetz im Zeitintervall t [ct/kWh].
c_p^ϕ	durchschnittlicher Strompreis für bezogenen Strom aus Verteilernetz [ct/kWh].
d_{max}	maximale Menge an Wärme in kWh, welche der Brennwertkessel in einem Zeitintervall t bereitstellen kann.
d_t	Wärmeproduktion des Brennwertkessels im Zeitintervall t in kWh.
e_b	Emissionsfaktor bei der Energieerzeugung des Mikro-BHKWs [g/kWh].
e_p	durchschnittlicher Emissionsfaktor des Strommixes im Verteilernetz [g/kWh].
$e_{p,t}$	Emissionsfaktor des Strommixes im Verteilernetz im Zeitintervall t [g/kWh].
e_p^ϕ	durchschnittlicher Emissionsfaktor für bezogenen Strom aus dem Verteilernetz [g/kWh].
$e_{elektr.}$	CO ₂ -Emissionen für die Stromversorgung eines Tages [g].
$e_{therm.}$	CO ₂ -Emissionen für die Wärmeversorgung eines Tages [g].
e_{total}	CO ₂ -Emissionen für die Energieversorgung eines Tages [g].
ε_i	Fehlerterm bei der Schätzung von Y_i .
f_t	Stromeinspeisung des Microgrids im Zeitintervall t in kWh.
$f_{t,n}$	Stromeinspeisung eines Haushaltes n im Zeitintervall t in kWh.
i_t	Zustandsänderung des Stromspeichers im Zeitintervall t in kWh.
i_t^-	negative Zustandsänderung des Stromspeichers im Zeitintervall t in kWh.
i_t^+	positive Zustandsänderung des Stromspeichers im Zeitintervall t in kWh.
i_t^*	optimale Zustandsänderung des Stromspeichers im Zeitintervall t .
l_t	Stromverlust durch Zwischenspeicherung im Zeitintervall t in kWh.
N	Anzahl der Haushalte im Microgrid.
p_{max}	Spitzenlast im Strombezug eines Tages in kWh.
p_t	Strombezug im Microgrid im Zeitintervall t in kWh.
$p_{t,n}$	Strombezug eines Haushaltes n im Zeitintervall t eines Tages in kWh.

\mathbf{p}	Strombezugsvektor für einen Tag des Micogrids.
\mathbf{p}_n	Strombezugsvektor für einen Tag eines Haushaltes n .
$r_{\text{CO}_2, \text{abs.}}$	absolute Reduktion der CO_2 -Emissionen.
$r_{\text{CO}_2, \text{rel.}}$	relative Reduktion der CO_2 -Emissionen.
$r_{\text{costs, abs.}}$	absolute Reduktion der Betriebskosten.
$r_{\text{costs, rel.}}$	relative Reduktion der Betriebskosten.
s_t	Solarstromerzeugung im Microgrid im Zeitintervall t in kWh.
$\tilde{s}_{\tilde{t}}$	Solarstromerzeugung im Microgrid zum Zeitpunkt \tilde{t} in kW.
$s_{t,m}$	Solarstromerzeugung einer PV-Anlage m im Zeitintervall t in kWh.
\mathbf{s}	Vektor der Solarstromerzeugung für einen Tag im Microgrid.
\mathbf{s}_m	Vektor der Solarstromerzeugung für einen Tag einer PV-Anlage m .
S	Trainingszeitraum der Prognoseverfahren.
t	Zähler von Zeitintervallen.
\tilde{t}	Zeitpunkt im Zeitintervall t .
T	Zeitraum der Datenreihen, bzw. der Simulation.
u_t	Differenz des Solarstroms s_t und des Bedarfs y_t im Zeitintervall t .
$\tilde{u}_{\tilde{t}}$	Differenz der Leistung des Solarstroms $\tilde{s}_{\tilde{t}}$ und des Bedarfs $\tilde{y}_{\tilde{t}}$ zum Zeitpunkt \tilde{t} .
$v_{a,t}$	Hilfsvariable zur Steuerung des Mikro-BHKWs.
$v_{b1,t}$	Hilfsvariable zur Steuerung des Mikro-BHKWs.
$v_{b2,t}$	Hilfsvariable zur Steuerung des Mikro-BHKWs.
v_c	Hilfsvariable zur Steuerung des Mikro-BHKWs.
v_{t_c}	Hilfsvariable zur Steuerung des Mikro-BHKWs.
y_t	Strombedarf im Zeitintervall t in kWh.
$\tilde{y}_{\tilde{t}}$	Strombedarf zum Zeitpunkt \tilde{t} in kW.
$y_{t,n}$	Strombedarf eines Haushaltes n im Zeitintervall t .
y_{t,n_a}	Strombedarf eines Verbrauchers $a \in A_n$ im Zeitintervall t .
y_{gesamt}	Gesamtstrombedarf.
\mathbf{y}	Strombedarfsvektor für einen Tag des Microgrids.
\mathbf{y}_n	Strombedarfsvektor für einen Tag eines Haushaltes n .
\mathbf{y}_{-n}	Strombedarfsvektor für einen Tag aller Haushalte im Microgrid außer dem Haushalt n .
$\mathbf{y}_{n,a}$	Strombedarfsvektor für einen Tages des Verbraucher a der Wohnung n .
$\bar{\mathbf{y}}_{n,a}$	festes Lastprofil eines verschiebbaren Verbrauchers a der Wohnung n .
\mathbf{y}_n^*	optimale Lastallokationen für einen Haushalt n innerhalb eines Tages.
\mathbf{y}^*	optimale Lastallokationen des Microgrids innerhalb eines Tages.
\mathcal{Y}	Menge der möglichen Gesamtbedarfsvektoren für das Microgrid.
\mathcal{Y}_n	Menge des möglichen Bedarfsvektoren für einen Haushalt n .

$\mathcal{Y}_{n,a}$	Menge der möglichen Lastallokationen für den Verbraucher a einer Wohnung n .
\mathbf{x}_t	Regressoren/Input-Variablen zur Abschätzung von Y_t .
$(Y_t)_{t \in T}$	diskrete Zeitreihe für den Zeitraum T .
Y_t	Verbrauchswert des Zeitintervalls t .
\hat{Y}_t	Prognose des Verbrauchswertes Y_t .

Abbildungsverzeichnis

1	Optimierung der lokalen Energieerzeugung	vi
2	Optimierung der Nachfrage mittels DSM-Verfahren	vii
3	Prognosegüte von kurzfristigen Stromlastprognosen mittels linearer Regression	viii
2.1	Modelliertes Microgrid zur Optimierung der Energiezeugung	13
2.2	Spezifische Kohlenstoffdioxid-Emissionen des deutschen Strommixes .	16
2.3	Aktivitätsdiagramme zur Betriebsführung im Microgrid	26
2.4	Monatliche Strom- und Wärmebedarfe der modellierten Microgrids .	29
2.5	Beispieltage für die optimierte Betriebsführung im Microgrid im Juli	36
2.6	Beispieltage für die optimierte Betriebsführung im Microgrid im Oktober	37
2.7	Monatliche Anteile der unterschiedlichen Komponenten an der Stromversorgung	40
2.8	Ergebnisse der Robustheitsanalyse	44
3.1	Koordinative Verhandlungsstrategie zwischen Haushalten zur Bestimmung der Lastverschiebungen	54
3.2	DSM Bsp. 1: Individuelle Lastverschiebungen zweier Haushalte . . .	65
3.3	DSM Bsp. 2: Mögliche Lastverschiebung bei koordinativem DSM . .	66
3.4	Beispieltag für die Anwendung von DSM-Verfahren	69
4.1	Dimensionen der Konzeptmatrix zur Gliederung der Literaturrecherche für STLF	85
4.2	Modell eines künstlichen neuronalen Netzes	91
4.3	Modellierung einer Hyperebene bei Support Vector Machines	92
4.4	Beispiele aussortierter Datensätze	103
4.5	Beispiele verwendeter Datensätze	105
4.6	Sliding Window Strategie	106
4.7	Empirische Autokorrelation und partielle Autokorrelation der Zeitreihe REDD.	108
4.8	Boxplots zu der empirischen Autokorrelation und partiellen Autokorrelation der Zeitreihen aus REFIT.	108
4.9	Boxplots zu der empirischen Autokorrelation und partiellen Autokorrelation der Zeitreihen aus CER.	109
4.10	Boxplots zu der empirischen Autokorrelation und partiellen Autokorrelation der saisonbereinigten Zeitreihen aus REFIT	111
4.11	Boxplots zu der empirischen Autokorrelation und partiellen Autokorrelation der saisonbereinigten Zeitreihen aus CER	111
4.12	Beispiel für einen zweistufigen Regressionsbaum	114
4.13	Konzept eines Random Forest	116

4.14 Streudiagramm der Variationskoeffizienten und der Prognosefehler	126
4.15 Regressionsfunktionen zur Abschätzung des Prognosefehlers	128
4.16 MAPE der linearen Regression bei steigendem Prognosehorizont	129

Tabellenverzeichnis

2.1	Übersicht der modellierten Komponenten zur Optimierung der Energieerzeugung im Microgrid	30
2.2	Spezifikation der Betriebskosten im Microgrid	32
2.3	Ergebnisse der Simulation zur optimierten Betriebsführung bei festem Strompreis mit Spitzenlastreduktion	38
2.4	Ergebnisse der Simulation zur optimierten Betriebsführung bei dem zeitabhängigen Stromtarif	39
2.5	Ergebnisse der Simulation zur optimierten Betriebsführung bei Real-Time-Pricing	39
2.6	CO ₂ -Emissionen für verschiedene Szenarien der Energieversorgung im Microgrid	41
2.7	Betriebskosten für verschiedene Szenarien der Energieversorgung im Microgrid	43
3.1	DSM-Algorithmus für koordinatives DSM	63
3.2	Ergebnisse der Simulation der DSM-Verfahren zur Glättung des Strombedarfs	71
3.3	Ergebnisse der Simulation der DSM-Verfahren zur Minimierung der Stromkosten bei RTP	72
3.4	Stromkosten bei DSM-Verfahren zur Glättung des Strombedarfs . . .	73
3.5	Stromkosten bei DSM-Verfahren zur Minimierung der Stromkosten und RTP	74
3.6	CO ₂ -Emissionen bei DSM-Verfahren zur Glättung des Strombedarfs	75
3.7	CO ₂ -Emissionen bei DSM-Verfahren zur Minimierung der Stromkosten und RTP	76
4.1	Klassifizierung der evaluierten Artikel anhand der Konzeptmatrix . .	95
4.2	Vergleich der Prognosegüte in der verwandten Literatur	99
4.3	Datensätze für die Evaluation der kurzfristigen Stromlastprognosen .	104
4.4	MAPE bzw. aMAPE der Prognoseverfahren für die durchgeführten Experimente	121
4.5	NMAE bzw. aNMAE der Prognoseverfahren für die durchgeführten Experimente	122
4.6	NRMSE bzw. aNRMSE der Prognoseverfahren für die durchgeführten Experimente	123
4.7	Analyse der Input-Variablen für die Stromlastprognosen einzelner Haushalte	130
4.8	Analyse der Input-Variablen für die Stromlastprognosen von zehn Haushalten	131

A.1	ADF-Teststatistiken und p -Werte für die Datenreihen aus CER . . .	142
-----	--	-----

Smart Energy made in Microgrids

Contents

1.1	Hintergrund	1
1.2	Ziele der Arbeit	3
1.3	Vorgehensweise	4

1.1 Hintergrund

„Smart Energy made in Microgrids“, so könnte der Slogan der vorliegenden Arbeit lauten – in Anlehnung an den Titel der durch das Bundesministerium für Wirtschaft und Technologie (BMWi) ins Leben gerufenen Förderinitiative „E-Energy – Smart Energy made in Germany“. In dieser wurde in sechs großen Modellregionen von 2008 – 2013 erforscht, wie mittels moderner Informations- und Kommunikationstechnologien (IKT) die Versorgungssicherheit, die Wirtschaftlichkeit und die Umweltverträglichkeit der Energieversorgungssysteme gewährleistet und optimiert werden können (vgl. [4]). Die vorliegende Arbeit knüpft an die Erkenntnisse dieser Forschungsarbeiten an und untersucht, wie bereits auf der Ebene von Microgrids mittels der digitalen Vernetzung und der Anwendung mathematischer Optimierungsmethoden die Energiebilanzen so optimiert werden können, dass die Kohlenstoffdioxidemissionen reduziert und ein Beitrag zur Netzstabilität der Energienetze geleistet werden kann.

Vor dem Hintergrund der globalen Erderwärmung besteht unter den Klimaforschern weltweit breiter Konsens über die Notwendigkeit, die Emissionen von Treibhausgasen deutlich zu reduzieren, um die Auswirkungen des Klimawandels abzumildern. In den europäischen Klimazielen ist daher eine Reduktion der Treibhausgasemissionen von mindestens 40% bis 2030 und eine Reduktion von 80% bis 95% bis 2050 gegenüber den Referenzwerten von 1990 vorgesehen (vgl. [5, 6]). Bei der Energiegewinnung durch die Verbrennung fossiler Energieträger werden große Mengen an Kohlenstoffdioxid (CO_2) freigesetzt, was als Hauptursache des anthropogenen Treibhauseffektes angesehen wird (vgl. [7–9]). Daher ist in den europäischen Klimazielen eine Erhöhung des Anteils der erneuerbaren Energien an der Stromerzeugung auf mindestens 27% und eine Erhöhung der Energieeffizienz auf ebenfalls mindestens 27% bis 2030 festgehalten (vgl. [10, 11]). In Deutschland wird ein Anteil von rund 40% der Treibhausgasemissionen durch den Energiesektor verursacht, obwohl bereits 13,5% des Bruttoenergieverbrauchs durch erneuerbare Energien bereitgestellt

wurden (Stand 2015, vgl. [12]). Dieser Anteil soll durch den Ausbau der erneuerbaren Energien und deren intelligente Einbindung in die Energienetze erhöht werden. Insbesondere in der Stromerzeugung soll nach dem Klimaschutzplan 2050 der Anteil der erneuerbaren Energien von aktuell 32% auf 80% bis zum Jahre 2050 deutlich gesteigert werden (vgl. [12]).

Der Ausbau der erneuerbaren Energien wird in Deutschland dementsprechend vorangetrieben. In den letzten zehn Jahren hat sich die installierte Erzeugungsleistung der Windkraft- und Photovoltaikanlagen von 23 Gigawatt (GW) auf 84 GW mehr als verdreifacht (vgl. [13, 14]). Durch diese Neuausrichtung der Stromversorgung werden die Stromnetze dezentraler und ein Teil der Stromerzeugung dargebotsabhängig und volatil. Dies führt dazu, dass zu manchen Zeiten die Stromerzeugung die Nachfrage übersteigt und Kraftwerke durch Redispatchmaßnahmen abgeregelt werden müssen. Zu anderen Zeiten wird kaum Strom mittels erneuerbaren Energieanlagen erzeugt und die Nachfrage muss durch den teuren Betrieb von Spitzenlastkraftwerken gedeckt werden (vgl. [15]). Um dennoch einen effizienten Ressourceneinsatz zu gewährleisten, wird daran geforscht, wie durch den Aufbau sogenannter *Smart Grids*, in welchen die Akteure digital vernetzt sind, eine Verbesserung des Gesamtsystems erreicht werden kann. Durch das koordinierte Zusammenspiel von der Stromerzeugung über die Speicherung und das Netzmanagement bis hin zum Verbrauch soll eine gleichmäßigere Auslastung, ein effizienterer Betrieb der Kraftwerke und eine Reduktion der CO₂-Emissionen erreicht werden.

Nach einer aktuellen Studie des VDE von 2015 [1] wird die Grundlage für eine nachhaltige Entwicklung der Energieversorgung in einem zellularen Ansatz gesehen, in welchem ein Ausgleich von Erzeugung und Last bereits auf der niedrigsten möglichen Ebene erfolgen soll. Dazu werden sogenannte Energiezellen gebildet, welche auf der niedrigsten Ebene Wohneinheiten (Einfamilienhäuser, Blockbebauung, Hochhäuser), Gewerbe- und Handelsunternehmen oder Industriebetriebe sein können. Durch den Zusammenschluss jeweils mehrerer Zellen zu übergeordneten Zellen wird eine übergeordnete Ebene aufgebaut, in welcher wiederum in jeder Zelle eine möglichst ausgeglichene Energiebilanz angestrebt wird. Auf diese Weise soll ein günstigerer Energiebezug, eine Reduktion des Energiebedarfs, eine hohe Versorgungszuverlässigkeit und Umweltfreundlichkeit erreicht werden (vgl. [1]). Diese Handlungsempfehlung wird u.a. durch die Erkenntnisse der Modellstadt Mannheim gestützt, welche zu den sechs E-Energy Modellregionen gehörte. Gemäß diesen bedarf es einer zellularen Netzarchitektur, um der wachsenden Komplexität der Energiesysteme gerecht zu werden (vgl. [16]).

Sogenannte *Microgrids* bezeichnen einen lokalen Verbund von Energieerzeugern, Verbraucher und Speichereinheiten, welcher in koordinierter Weise betrieben werden kann (vgl. [17]). Ein solcher Verbund kann eine dezentrale Zelle in einem zellular aufgebauten System darstellen. Durch die lokale Optimierung der integrierten Akteure im Microgrid kann die lokal erzeugte Energie effizienter genutzt, Netzverluste vermieden und die übergeordneten Stromnetze entlastet werden.

1.2 Ziele der Arbeit

Aus den aufgezeigten Entwicklungen geht hervor, dass der Ausgleich von Energieerzeugung und Energienachfrage ein integraler Bestandteil in der Neuausrichtung der Energieversorgung darstellt. Der Aufbau und die Optimierung von Microgrids bieten dabei die Möglichkeit bereits dezentral das Zusammenspiel der lokalen Komponenten zu optimieren und so zu ausgeglicheneren Energienetzen beizutragen. In dieser Dissertation soll dargelegt werden, welche Methoden sich für die Optimierung der Energiebilanzen im Microgrid eignen und welche Effekte in einem solchem Verbund möglich sind.

Ein Microgrid wird nach dem Internationalen Forum für große elektrische Netze (CIGRÉ) definiert als „ein Stromverteilungssystem mit Lasten und dezentralen Energieressourcen (wie verteilten Erzeugern, Speichereinheiten und verschiebbaren Lasten), welches in kontrollierter und koordinierter Weise betrieben werden kann. Dabei ist es entweder an das öffentliche Stromnetz angeschlossen oder wird im Inselbetrieb betrieben“ (Ü.d.V. aus [17]). Ein Microgrid kann nach dieser Definition ein einzelnes Wohngebäude mit verschiebbaren Lasten, aber auch einen ganzen Stadtteil mit einer deutlich höheren Anzahl an lokalen Komponenten umfassen. In der vorliegenden Arbeit wird ein Microgrid in der Größe eines Wohnblocks mit mehreren Haushalten und optionalen Energieerzeugungsanlagen und Speichern betrachtet. Durch die begrenzte Größe eines solchen Microgrids fallen kaum Netzverluste an. Zudem können somit kleine Kraft-Wärme-Kopplungsanlagen wie Blockheizkraftwerke (BHKW) betrieben werden, um eine effiziente Strom- und Wärmeversorgung umzusetzen.

Um die Fragestellung nach geeigneten Methoden zur Optimierung eines solchen Energieverbundes zu beantworten, müssen entsprechende Algorithmen entwickelt und die Wirkung dieser in geeigneten Simulationen quantifiziert werden. Dabei können sowohl Optimierungsmethoden auf Seiten der lokalen Energieerzeugung als auch auf der Verbrauchseite zum Einsatz kommen. Obwohl sich bereits umfangreiche Arbeiten mit der Betriebsführung von kleinen BHKW befassen, werden diese noch nicht in den Kontext von Microgrids gesetzt, in welchen sie vernetzt mit Photovoltaikanlagen (PV-Anlagen) und Stromspeichern durch eine intelligente Steuerung zur Optimierung der Erzeugerseite beitragen können. Zudem fehlt es an Auswertungen auf der Basis realer Verbrauchsdaten. Die Anpassung des Strombedarfs wird als Demand Side Management (DSM) bezeichnet und obwohl auch in diesem Bereich die Anzahl der Veröffentlichungen in den letzten Jahren deutlich zugenommen haben und vielversprechende Ansätze für den Einsatz im häuslichen Kontext entwickelt wurden, fehlt es auch hier an Auswertungen auf Basis von realen Daten. Zudem existieren bisher kaum Studien, welche Aussagen über die Bedeutung von DSM im Hinblick auf die CO₂-Emissionen zulassen. In den verwendeten Optimierungsansätzen werden kurzfristige Stromlastprognosen für eine geringe Anzahl von Haushalten benötigt und es bedarf daher einer Analyse darüber, welche Prognosefehler zu erwarten sind. Die existierenden Analysen zu dieser Fragestellung weisen teilweise widersprüchliche Ergebnisse auf und können nicht reproduziert werden, da

sie auf meist projekt-internen Datensätzen durchgeführt wurden.

Ziel der vorliegenden Forschungsarbeit ist daher die Darstellung und die Entwicklung von Methoden, mit welchen die Energiebilanzen im Microgrid optimiert werden können, die quantitative Auswertung dieser auf geeigneten Simulationen sowie die Analyse von kurzfristigen Stromlastprognosen im Microgrid.

1.3 Vorgehensweise

Die Untersuchung teilt sich in drei Kapitel, in welchen jeweils ein Aspekt der Optimierung betrachtet wird:

- (1) Optimierung der lokalen Energieerzeugung im Microgrid,
- (2) Optimierung der Nachfrage durch Demand Side Management,
- (3) Analyse von kurzfristigen Stromlastprognosen für Wohngebäude.

Jedes der Kapitel umfasst eine eigenständige Analyse der aktuellen Forschung zu der jeweiligen Forschungsfrage und gibt eine Einordnung des eigenen Beitrags. In einem abschließenden Kapitel werden die zentralen Erkenntnisse nochmals zusammengefasst und gegenübergestellt.

Zu (1): Zur Optimierung der lokalen Energieerzeugung wird ein Microgrid konzipiert, in welches ein Mikro-BHKW und PV-Anlagen als lokale Stromerzeuger eingebunden sind. Eine grundlegende These dieses Kapitels ist, dass die Kombination eines Mikro-BHKWs mit PV-Anlagen zu einer erheblichen Reduktion der CO₂-Emissionen in der lokalen Energieversorgung führt. Aufgrund der simultanen Erzeugung von Strom und Wärme ist ein Mikro-BHKW äußerst effizient und umweltfreundlich, wenn sichergestellt werden kann, dass sowohl der erzeugte Strom als auch die erzeugte Wärme lokal genutzt werden. PV-Anlagen stellen hingegen hauptsächlich in der warmen Jahreszeit Strom bereit, wenn weniger Wärme benötigt wird. Um die Vorteile einer solchen Kombination auszuschöpfen, wird eine vorausschauende und koordinative Steuerung eines Mikro-BHKWs unter Berücksichtigung der anderen lokalen Komponenten im Microgrid entwickelt. Die angewandte Methodik ist dem Bereich des Operation Research zuzuordnen. Validiert wird der Ansatz auf zwei simulierten Microgrids mit unterschiedlichen Ausstattungen. Die Simulation ermöglicht eine Quantifizierung der Effekte im Hinblick auf die CO₂-Emissionen und die Betriebskosten. Der Auswertung schließt sich eine Diskussion über die Limitierungen des Ansatzes und der Ausblick an.

Zu (2): Zur Optimierung des lokalen Strombezugs werden geeignete DSM-Verfahren zur automatisierten Verschiebung von Haushaltslasten identifiziert, implementiert und ausgewertet. Dafür werden zunächst die möglichen Zielsetzungen von DSM analysiert. Durch die Lastverschiebungen kann entweder der lokale Strombezug

geglättet oder der Strombezug in Zeiten geschoben werden, in welchen in den übergeordneten Stromnetzen überdurchschnittlich viel Strom aus erneuerbaren Energien verfügbar ist. Die beiden Zielsetzungen werden separat untersucht. Zur Umsetzung werden zwei Ansätze aus der Literatur ausgewählt: 1) individuelles DSM, bei welchem in jedem Haushalt die Lastverschiebungen unabhängig von dem Verbrauch anderer Haushalten optimiert werden, 2) koordinatives DSM, bei welchem mittels eines Multi-Agenten-Systems zwischen den Haushalten im Verbund über die Lastverschiebungen verhandelt wird. Zu den typischen Lasten, welche in Haushalten verschoben werden können, gehören die Waschvorgänge von Spül- und Waschmaschinen sowie Trockner. Diese haben ein festes Lastprofil. Die ausgewählten DSM-Verfahren werden so modifiziert, dass sie diesem Lasttyp gerecht werden. Die adaptierten Verfahren werden auf simulierten Microgrids mit realen Verbrauchsdaten evaluiert und die Effekte im Hinblick auf die CO₂-Emissionen und die Betriebskosten quantifiziert. Der Auswertung folgt eine Diskussion über die weitergehenden Forschungsfragen im Kontext von DSM.

Zu (3): Zur Analyse der kurzfristigen Stromlastprognosen wird zunächst ein sehr umfassender Literaturreview nach dem Konzept von vom Brocke [3] durchgeführt, durch welchen die Defizite der bisherigen Analysen in diesem Bereich deutlich werden. Die existierenden Analysen zu dieser Fragestellung weisen teilweise widersprüchliche Ergebnisse auf und sind, da sie auf meist projekt-internen Datensätzen durchgeführten wurden, nicht reproduzierbar. Daher werden umfassende Experimente zur Analyse der Prognosegüte von kurzfristigen Stromlastprognosen durchgeführt. Es werden sieben State-of-the-Art Verfahren aus dem Bereich der statistischen Zeitreihenanalyse und der künstlichen Intelligenz implementiert und auf 165 Datenreihen evaluiert. Die Datenreihen entstammen öffentlich verfügbaren Datensätzen, so dass reproduzierbare Benchmarks aufgestellt werden. Die erreichten Prognosegenauigkeiten werden im Hinblick auf Skalierungseffekte, Prognosehorizont und Input-Variablen analysiert. Aus der Analyse werden Empfehlungen für die Implementierung von kurzfristigen Stromlastprognosen im Microgrid abgeleitet.

Optimierung eines Mikro-BHKWs im Microgrid

Contents

2.1	Ansatz	7
2.2	Grundlagen und verwandte Arbeiten	7
2.2.1	Variable Strompreise	8
2.2.2	Betriebsführung von BHKW	9
2.2.3	Abgrenzung des eigenen Forschungsansatzes	11
2.3	Modellierung	12
2.3.1	Gesamtkonzeption des Microgrids	12
2.3.2	Modellierung der Komponenten	12
2.3.3	Modellierung der CO ₂ -Emissionen	14
2.3.4	Modellierung der Betriebskosten	16
2.3.5	Optimierungsproblem	18
2.3.6	Betriebsmodus	24
2.4	Simulation	28
2.4.1	Spezifikation der Komponenten	28
2.4.2	Spezifikation der Betriebskosten	31
2.4.3	Spezifikation der Kennzahlen	32
2.4.4	Aufbau der Robustheitsanalyse	34
2.5	Ergebnisse der Simulation	35
2.5.1	Energiebilanzen	36
2.5.2	Ökobilanzen	40
2.5.3	Analyse der Betriebskosten	42
2.5.4	Reduktion der Spitzenlasten	43
2.5.5	Robustheitsanalyse	44
2.6	Diskussion	45
2.6.1	Einschränkende Faktoren	45
2.6.2	Weitergehende Forschungsfragen	46
2.7	Zusammenfassung	47

2.1 Ansatz

Die These des vorliegenden Kapitels ist, dass Mikro-BHKW durch einen optimierten Betrieb in Kombination mit weiteren lokalen Komponenten wie PV-Anlagen und Stromspeichern einen wertvollen Beitrag zur Erreichung der eingangs formulierten Klimaziele leisten können. Mikro-BHKW weisen eine hohe Energieeffizienz auf, sofern sowohl der produzierte Strom als auch die produzierte Wärme lokal Verwendung finden. Im Folgenden wird ein Betriebsmodus entwickelt, der diesen Vorteil nutzt, und gezeigt, dass durch eine vorausschauende Betriebsführung eines Mikro-BHKWs im Microgrid die CO₂-Emissionen wesentlich reduziert werden können. Die Betriebsführung ist so konzipiert, dass lokale Komponenten wie PV-Anlagen und Energiespeicher berücksichtigt werden können. Sind diese integriert, werden durch die koordinative Optimierung weitere Einsparungen in den CO₂-Emissionen erreicht.

Es wird ein Modell für ein Microgrid konzipiert, welches aus mehreren Wohnungen, einem Mikro-BHKW, einem zusätzlichen Brennwertkessel sowie einem Wärmespeicher besteht und in das optional PV-Anlagen sowie ein Stromspeicher integriert sind. Die primäre Zielsetzung der Optimierung liegt darin, die CO₂-Emissionen zu reduzieren. Als nachrangiges Optimierungsziel sollen die Betriebskosten reduziert werden, wobei sowohl feste Strompreise als auch zeitvariable Stromtarife modelliert werden. Zur Bestimmung des neuen Betriebsmodus des Mikro-BHKWs werden Prognosen des Energiebedarfs und der (optionalen) Solarstromerzeugung der PV-Anlagen für die nächsten 24 Stunden verwendet. Für die prognostizierten Umstände wird die optimale Betriebsführung zur Reduktion der CO₂-Emissionen berechnet. Ausgehend von dieser Lösung werden Handlungsempfehlungen abgeleitet, welche dann in Abhängigkeit von den tatsächlichen Zuständen im Microgrid realisiert werden. In der Modellierung werden die Größen der Komponenten im Microgrid zunächst nicht festgelegt. Sie gehen als Parameter in das Optimierungsproblem ein, so dass dieses möglichst allgemein aufgestellt wird. In der Simulation werden wirtschaftliche Faktoren in der Auslegung der Komponenten berücksichtigt und die Parameter entsprechend spezifiziert.

Zur Evaluation dieses Vorgehens werden zwei Microgrids simuliert, für welche jeweils mit unterschiedlichen Ausstattungen der neue Betriebsmodus evaluiert wird. Dabei werden unter anderem fehlerbehaftete Prognosen zum Strombedarf, dem Wärmebedarf und der Solarstromerzeugung evaluiert und geprüft, wie sensitiv der Betriebsmodus auf die veränderten Eingabewerte reagiert. In der Auswertung der Energiebilanzen wird quantifiziert, welchen Anteil die jeweiligen Energieanlagen der simulierten Microgrids an der Energieversorgung haben und was dies für die CO₂-Emissionen und die Betriebskosten impliziert.

2.2 Grundlagen und verwandte Arbeiten

Zu den europäischen Klimazielen bis 2030 gehören drei wesentliche Ziele: (1) eine Reduktion der Treibhausgasemissionen von mindestens 40% gegenüber 1990, (2) eine Erhöhung des Anteils der erneuerbaren Energien am Energieverbrauch auf mindes-

tens 27% und (3) eine Erhöhung der Energieeffizienz von ebenfalls mindestens 27% (vgl. [5, 10, 11]). Diese Ziele wurden in der UN- Klimakonferenz in Paris 2015 nochmals verschärft. In Deutschland sollen die Treibhausgasemissionen nach dem entwickelten Klimaschutzplan bis 2050 um 80 bis 95% reduziert werden. Die Nutzung von Kraft-Wärme-Kopplung (KWK) kann zu jedem dieser Ziele beitragen, solange sichergestellt ist, dass sowohl Strom als auch Wärme genutzt werden.

Große Anlagen mit Kraft-Wärme-Kopplung sind bereits seit Jahrzehnten im Einsatz, während kleine Anlagen lange Zeit als zu teuer galten. Dieser Umstand änderte sich mit den steigenden Energiepreisen und dem Fortschritt in der Entwicklung kleiner Motoren, wodurch kleine, sogenannte Blockheizkraftwerke an Attraktivität gewannen. Die ersten Anlagen für Wohnblöcke gingen 1996 in Serienproduktion. Weitere Modelle kamen nach 2000 auf den Markt (vgl. [18]). In Deutschland sind verschiedene Fördermechanismen mit dem Kraft-Wärme-Kopplungsgesetz 2009 und dem Erneuerbaren-Energien-Wärme-gesetz 2008 erlassen worden, um KWK-Kopplung als nachhaltige Technologie auch für Endverbraucher attraktiv zu machen. Über die letzten Jahre sind verschiedene Betriebsmodi für BHKW zur lokalen Energieversorgung von Wohnblöcken entwickelt und untersucht worden. Im Folgenden wird eine Übersicht über verschiedene Ansätze gegeben. Da im Kontext von Smart Grids variable Strompreise eine wichtige Rolle spielen und diese daher in vielen Forschungsansätzen zur der Optimierung von BHKW berücksichtigt werden, wird ein Überblick über die üblicherweise modellierten Tarife vorangestellt.

2.2.1 Variable Strompreise

Ein Anreiz zur Vermeidung von hohen Netzlastfluktuationen sind variable Strompreise. Diese sind vor allem in den USA bereits ein Instrument, um Spitzenlasten zu vermeiden. Dabei werden diese Tarife derzeit hauptsächlich im Gewerbe und der Industrie genutzt (vgl. [19]). In Deutschland sind seit 2011 Stromanbieter nach dem Energiewirtschaftsgesetz¹ verpflichtet, variable Energiepreise anzubieten. Dabei kommen bisher hauptsächlich Hoch- und Niederlast-Tarife zum Einsatz. Durch die steigende Anzahl von digitalen Stromzählern in Haushalten, welche ebenfalls nach dem Energiewirtschaftsgesetz bei größeren Renovierungen oder Neubauten installiert werden müssen², werden variablere Strompreise möglich, die von der prognostizierten oder tatsächlichen Auslastung im Netz abhängen. Zwei häufig verwendete Modelle werden in der Optimierung evaluiert und sollen daher näher beschrieben werden. Die Definitionen der Tarifmodelle können sich je nach Quelle leicht unterscheiden. Die verwendeten Definitionen entsprechen der Notation aus [20].

2.2.1.1 Time-of-Use Pricing

Als *Time-of-Use* (TOU) Tarife bezeichnet man Tarife, bei denen der Strompreis tageszeitabhängig variiert. Die Zeitintervalle, für die derselbe Preis gilt, sind üblicher-

¹ § 40 Abs. 5 EnWG

² § 21 b Abs. 3a, § 14a EnWG

weise größer als eine Stunde und es gibt in der Regel nur zwei bis drei Unterteilungen für einen Tag. Der tageszeitabhängigen Preise sind im Voraus bekannt.

Nieder- und Hochlasttarife sind ein typisches Beispiel für einen in Deutschland verwendeten TOU-Tarif. Dabei wird i. d. R. nachts ein günstigerer Preis für den verbrauchten Strom veranschlagt. Teilweise gilt auch am Wochenende der günstigere Tarif. Die Zeitintervalle und tageszeitabhängigen Preise sind bereits im Vertrag festgelegt und gelten i.d.R. für mindestens sechs Monate.

2.2.1.2 Real Time Pricing

Als *Real Time Pricing* (RTP) bezeichnet man Tarife, bei denen sich der Strompreis an den an der Strombörse gehandelten Kursen orientiert und daher typischerweise stündlich fluktuiert. Dabei muss unterschieden werden zwischen Tarifen, die bereits einen Tag vorher bekannt gegeben werden und die sich am Day-ahead-Markt orientieren und denjenigen, die jeweils erst eine Stunde vorher bekannt gegeben werden.

2.2.2 Betriebsführung von BHKW

Der Betriebsmodus eines BHKWs hängt von seiner Größe und dem Kontext ab, in dem es genutzt wird. Größere BHKW sind oft an das Fernwärmesystem angebunden und werden dann i.d.R. *stromgeführt* betrieben. Die Leistungsabgabe des BHKWs richtet sich nach dem Strombedarf oder der maximalen Kapazität der Anlage; die erzeugte Wärme wird in das Fernwärmenetz eingespeist oder geht als Abwärme verloren. Dagegen sind Blockheizkraftwerke in Wohngebieten, in Mehr- und Einfamilienhäusern meist *wärmegeführt*. In diesem Fall richtet sich die Leistungsabgabe des BHKWs nach dem lokalen Wärmebedarf. Da in diesem Fall der Betrieb auf die Wärmeversorgung ausgelegt ist, ist die Strombereitstellung nicht bedarfsgerecht. Der überschüssige Strom wird rückeingespeist. Dies führt zu hohen Netzlastfluktuationen. Diese BHKW haben i.d.R. eine elektrische Leistung kleiner als 15 kW und werden oft (vgl. [21]) als Mikro-BHKW bezeichnet. Ein solches Mikro-BHKW soll in der vorliegenden Arbeit als Komponente eines Microgrids optimiert werden. Im Folgenden werden zunächst die bestehenden Forschungsarbeiten zu Mikro-BHKW und deren Ergebnisse vorgestellt.

Die Wirtschaftlichkeit von Mikro-BHKW ist wesentlich abhängig von der Dauer des Betriebs. Nach [18] sind über 2000 Betriebsstunden im Jahr für einen wirtschaftlichen Betrieb notwendig. Dies kann bei einer angemessenen Größenwahl des BHKWs bereits durch einen wärmegeführten Betrieb erreicht werden. In der aktuellen Forschung zu Mikro-BHKW sind komplexere Betriebsmodi entwickelt und in Bezug auf die jährlichen Betriebskosten und die jährlichen Kohlenstoffdioxidemissionen untersucht worden. So wurden in der Studie von [22] ein wärmegeführter, ein stromgeführter und ein kostenoptimierter Betrieb verglichen. Die niedrigsten CO₂-Emissionen werden dabei für den wärmegeführten Betriebsmodus erreicht, da in den anderen Betriebsarten mehr Wärme produziert wird, als vor Ort benötigt, und diese als Abwärme abgeführt werden muss.

Um eine hohe Auslastung eines BHKWs zu erreichen und gleichzeitig einen möglichst hohen Anteil der produzierten Wärme zu nutzen, können Wärmespeicher in den Betrieb integriert werden. Durch sie wird die Stromerzeugung bis zu einem gewissen Grad von der Wärmeerzeugung entkoppelt. In den Arbeiten von [23] und [24] wird untersucht, welche Effekte Wärmespeicher auf den Betrieb eines Mikro-BHKWs haben und wie der Wärmespeicher dimensioniert sein soll. Es wird gezeigt, dass durch einen Wärmespeicher die Wirtschaftlichkeit eines Mikro-BHKWs erhöht werden kann. Die optimale Größe des Wärmespeichers ist dabei abhängig von dem Verhältnis von Strom zu Wärme in der Nachfrage und von dem Verhältnis von elektrischer zu thermischer Leistung des Mikro-BHKWs. In der Studie von [25] wird darüber hinaus gezeigt, dass bereits ein relativ kleiner Wärmespeicher zu wesentlich höheren Laufzeiten eines Mikro-BHKWs führen kann, wenn dafür in Kauf genommen wird, dass ein kleiner Anteil der Wärme nicht genutzt wird. Dies führt zu kürzeren Amortisationszeiten der Investitionen.

In den bisher beschriebenen Operationsmodi wird das Mikro-BHKW abhängig von der aktuellen Nachfrage nach Strom oder Wärme, der aktuellen Auslastung des Wärmespeichers und eventuell der aktuellen Tageszeit reguliert. In den Arbeiten von [26–29] werden prädiktive Ansätze vorgestellt, in welchen der Betrieb für einen bestimmten Zeitraum im Voraus geplant wird. In die Planung werden der erwartete Verbrauch an Strom und Wärme sowie die Nebenbedingungen, die sich durch die Leistungsgrenzen der Module ergeben, berücksichtigt. Diese Methodik erweist sich insbesondere dann als lukrativ, wenn variable Strompreise vorliegen und diese in die Planung miteinbezogen werden. Die Studien [26–28] gehen darüber hinaus davon aus, dass auch die Einspeisevergütung variabel ist. Durch die vorausschauenden Betriebsmodi werden die Betriebskosten in den Simulationen zwischen 26% bis 60% gesenkt. Die Reduktion hängt dabei wesentlich von den modellierten Strompreisen und der modellierten Einspeisevergütung ab. In der Arbeit von [30] wird ein vorausschauender Betriebsmodus eines BHKWs im Zusammenspiel mit einer Stromsenke betrachtet. Letztere nimmt Strom zu Zeiten auf, in denen er sehr günstig importiert werden kann und generiert damit ebenfalls Wärme. Dieser Ansatz ist hauptsächlich für Länder interessant, in denen ein hoher Wärmebedarf über das ganze Jahr vorliegt.

Das Hauptaugenmerk in der Forschung zur optimalen Betriebsführung von Mikro-BHKW liegt auf der Kombination derselben mit Wärmespeichern. Die Kombination mit weiteren Komponenten ist weniger gut erforscht. Es gibt einige Arbeiten, die sich mit der Einbindung von elektrischen Speichern beschäftigen, um den Primärenergieverbrauch zu reduzieren. Dazu gehören [31] und [32]. In [31] wird der Betrieb von verschiedenen Mikro-BHKW zur Strom- und Wärmeversorgung eines Hauses mit Strom- und Wärmespeichern simuliert. Der Stromspeicher wird dazu verwendet, sowohl überschüssigen Strom des BHKWs als auch Strom aus dem Netz aufzunehmen, wenn dieser günstig ist, und ihn abzugeben, wenn der Strombedarf nicht durch das BHKW gedeckt werden kann und der Strompreis hoch ist. Der simulierte Betrieb des BHKWs ist wärmegeführt. In der Simulation auf Standardlastprofilen wird der Primärenergieverbrauch auf diese Weise um bis zu 35% gesenkt. Es

werden 30 - 80% – abhängig vom Modell des BHKW – des Strombedarfs durch das BHKW gedeckt. Dies ist ein sehr hoher Anteil, der teilweise darauf zurückzuführen ist, dass der Jahresbedarf an Wärme im Verhältnis 6:1 gegenüber dem Strombedarf modelliert wird und erst damit sehr hohe Laufzeiten des BHKWs auch unter einem wärmegeführten Betrieb erreicht werden können. In [32] wird dieser Ansatz auf ein BHKW mit SOFC-Brennstoffzellen (Solid Oxide Fuel Cells) als Antrieb übertragen. Die Stromkennzahl dieser Anlagen liegt zwischen 0.5 und 0.6 (Verhältnis Strom-zu Wärmeleistung), wodurch eine hohe Auslastung des BHKWs erreicht werden. Gemäß der anschließenden betriebswirtschaftlichen Analyse ist ein solches System bei einer Amortisationszeit von 10 Jahren und einem Zinssatz von 5% wirtschaftlich, wenn die Anschaffungskosten für das Mikro-BHKW weniger als 3000 Euro/kW betragen.

Der kombinierte Betrieb von Mikro-BHKW und PV-Anlagen wurden nach dem aktuellen Forschungsstand kaum betrachtet. Dabei ergänzen sich die beiden Anlagen über den Jahresverlauf: PV-Anlagen erzeugen viel Energie im Sommer, wenn der Wärmebedarf gering ist, während BHKW nachhaltig im Winter eingesetzt werden können, wenn der Wärmebedarf hoch ist. Eine relativ neue Studie aus 2015 [33] untersucht dieses Konzept: Es werden 30 Haushalte mit jeweils einer kleinen Solaranlage, einem kleinen Mikro-BHKW und Speichern simuliert, mit der Zielsetzung einen möglichst hohen Anteil des Eigenbedarfs durch die Komponenten vor Ort decken zu können. Das BHKW wird in zwei On/Off Zyklen (beginnend um 5:00 und 16:00 Uhr) betrieben, um so die üblichen Peaks im Wärmebedarf durch das BHKW abzudecken. In der Studie kann 72% des Strombedarfs durch die lokalen Komponenten generiert werden. Dabei werden 23% des Strombedarfs direkt durch die Solaranlage und 22% direkt durch das Mikro-BHKW gedeckt. Weitere 27% werden durch eine Zwischenspeicherung des Solarstroms und des durch das BHKW erzeugten Stroms erreicht. Der Stromspeicher trägt wesentlich zur Erhöhung der Eigenproduktion bei: Ohne die Möglichkeit, Strom zwischenzuspeichern, verringert sich der Anteil auf 55%.

In den genannten Veröffentlichungen konnte gezeigt werden, dass durch eine optimierte Betriebsführung eines Mikro-BHKWs die Betriebskosten für die Strom- und Wärmeversorgung gesenkt werden können. Dies gilt ebenso für die CO₂-Emissionen, wobei die Reduktion davon abhängt, in welchem Umfang die erzeugte Wärme genutzt wird. Eine vorausschauende Steuerung kann bei variablen Strompreisen zu einer zusätzlichen Reduktion der Betriebskosten führen.

2.2.3 Abgrenzung des eigenen Forschungsansatzes

Die These der vorliegenden Arbeit ist, dass die Kombination eines Mikro-BHKWs mit weiteren Komponenten wie Stromspeichern und PV-Anlagen unter einer *koordinierten, prädiktiven Betriebsführung* zu weiteren Einsparungen sowohl in den CO₂-Emissionen als auch den Betriebskosten führt. Dabei steht die Reduzierung der CO₂-Emissionen an erster Stelle.

Zusätzlich wird ein weiterer Punkt aufgenommen, der bisher in der Forschung

zu dem optimierten Betrieb von BHKW noch nicht adressiert wird, aber in Smart Grids und Micro Grids eine wesentliche Rolle spielt: die Reduktion von Spitzenlasten. Energieversorger haben ein Interesse an einem möglichst ausgeglichenem Strombezug der Verbraucher, da somit der Bezug von Strom aus Spitzenlastkraftwerken vermieden wird, der i.d.R. relativ teuer ist (vgl. [15]). Zeitvariable Stromtarife sind eine Möglichkeit, indirekt Einfluss auf die Zeiten des Strombezugs zu nehmen, und sie werden daher als ein Modell in der Simulation aufgenommen. Eine gezielte Optimierung hin zu einem gleichmäßigen Stromimport ist jedoch bisher – soweit bekannt – noch nicht untersucht worden. Die Zielsetzung den lokalen Strombezug zu glätten wird daher ebenfalls modelliert und als nachgelagertes Optimierungsziel in die Optimierung aufgenommen.

2.3 Modellierung

Es wird ein Microgrid konzipiert und die Modellierung der Komponenten vorgestellt. Die Größen der Komponenten werden dabei durch Parameter gegeben, so dass das Optimierungsproblem unabhängig von der Größenwahl aufgestellt werden kann. In der Simulation werden die Komponenten spezifiziert und dabei wirtschaftliche Faktoren in der Auslegung der Komponenten berücksichtigt.

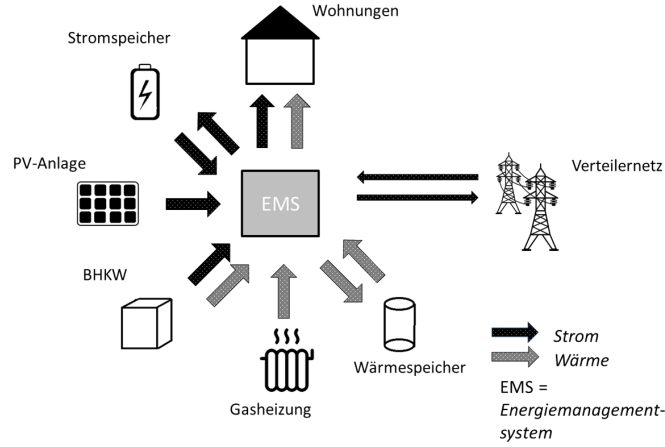
2.3.1 Gesamtkonzeption des Microgrids

Ein Microgrid besteht aus einem Verbund von Energieverbrauchern, Energieerzeugern und Speichern, die über Informations- und Kommunikationstechnologien miteinander verbunden sind und deren regulierbare Einheiten darüber gesteuert werden können. Für die Modellierung einer optimierten Betriebsführung wird ein Microgrid für einen Wohnblock bestehend aus mehreren Wohnungen konzipiert, welches den Wohnblock nachhaltig mit Strom und Wärme versorgen soll. Dafür werden ein Mikro-BHKW und optionale PV-Anlagen als Stromerzeuger in das Modell integriert. Zudem wird angenommen, dass ein Stromanschluss zu einem Niederspannungsnetz besteht, so dass bei Bedarf Strom importiert oder eingespeist werden kann. Darüber hinaus wird ein Warmwasserspeicher aufgenommen, um die Wärmeerzeugung zumindest teilweise vom Wärmebedarf zu entkoppeln. Zusätzlich wird angenommen, dass Brennwertkessel vorhanden sind, um den Wärmebedarf abzudecken, welcher nicht durch das BHKW gedeckt werden kann. Als weitere optionale Komponente wird ein Stromspeicher modelliert, um so ggf. Strom zwischenspeichern und Lastspitzen im Stromimport zu vermeiden. Eine Skizze zum Konzept ist in Abb. 2.1 dargestellt.

2.3.2 Modellierung der Komponenten

Die Betriebsführung des Mikro-BHKWs soll auf Basis einer am Tag zuvor durchgeführten Optimierung erfolgen. Dazu wird der Tag in 96 Zeitintervalle von jeweils 15

³ Die Icons für die Gasheizung und das Verteilernetz sind von Freepik: www.flaticon.com


 Abbildung 2.1: Komponenten des modellierten Microgrids³

Minuten unterteilt. Es wird angenommen, dass die Prognosen für den Energiebedarf und die Solarstromerzeugung ebenfalls in 15 Minuten Intervallen gegeben sind. Diese gehen als Inputparameter in das Optimierungsproblem ein. Weitere Inputparameter sind spezifische Eigenschaften der lokalen Komponenten. Die Prognosen und die weiteren Inputparameter werden im Folgenden modelliert.

2.3.2.1 Energiebedarf

Sei $y_t \in \mathbb{R}^+$ für $t \in \{1, \dots, 96\}$ der prognostizierte Strombedarf gegeben in kWh, der in dem t -ten Zeitintervall des Tages benötigt wird. Sei analog dazu $h_t \in \mathbb{R}^+$ der prognostizierte Wärmebedarf ebenfalls in kWh für das Zeitintervall t .

2.3.2.2 Solarstromerzeugung

Sei $s_t \in \mathbb{R}^+$ der prognostizierte Solarstrom in kWh, der durch PV-Anlagen im Microgrid in dem Zeitintervall t voraussichtlich bereitgestellt wird. Die Angabe beschreibe den Solarstrom abzüglich der geschätzten Verluste der Anlage durch Temperatur und geringe Bestrahlungsstärke sowie der Verluste in den Kabeln und der Wechselrichter.

2.3.2.3 BHKW

Es wird angenommen, dass der Betrieb des BHKWs sich innerhalb modellspezifischer Leistungsgrenzen modulieren lässt. Dabei seien $b_{min}, b_{max} \in \mathbb{R}^+$ die maximale, bzw. die minimale Menge an Strom in kWh, die das BHKW in einem Zeitintervall bereitstellen kann, ohne ausgeschaltet zu werden. Sei $b_t \in [0] \cup [b_{min}, b_{max}]$ die erzeugte Strommenge in einem Zeitintervall t . Die Stromkennzahl sei $1/\varphi_b$ mit $\varphi_b \in \mathbb{R}^+$. Diese Zahl beschreibt das Verhältnis von elektrischer zu thermischer Leistung. Die bereitgestellte Wärme in einem Intervall t ist daher $\varphi_b b_t$. Der Wirkungsgrad des

BHKWs sei η_b . Die Betriebsführung b_t soll im Hinblick auf die Reduktion der CO₂-Emissionen optimiert werden.

2.3.2.4 Brennwertkessel und Warmwasserspeicher

Sei $d_t \in [0, d_{max}]$ für $t \in \{1, \dots, 96\}$ die Wärmeproduktion des Brennwertkessels. Die Kapazitätsgrenze d_{max} beschreibt die maximale Menge an Wärme in kWh, welche der Brennwertkessel in einem Zeitintervall bereitstellen kann. Der Betrieb des Brennwertkessels und des Warmwasserspeichers werden nicht im Detail betrachtet. Es wird angenommen, dass der Warmwasserspeicher groß genug ist, um die durch das BHKW erzeugte Wärme im Laufe eines Tages zwischenspeichern, sofern das BHKW nicht mehr als den Tageswärmebedarf generiert. Wird mehr Wärme benötigt, wird der Brennwertkessel gestartet. Es wird angenommen, dass der Brennwertkessel und das BHKW denselben Wirkungsgrad haben. Verluste durch die Zwischenspeicherung der Wärme werden in der Modellierung zur Vereinfachung vernachlässigt.

2.3.2.5 Stromspeicher

Der Stromspeicher wird dazu verwendet, den durch das BHKW oder die PV-Anlagen erzeugten Strom zwischenspeichern. Sei $a_{max} \in \mathbb{R}^+$ die Kapazität des Speichers und a_t der Zustand des Speichers zu Beginn eines Zeitintervalls t . Sei η_a der Wirkungsgrad des Energiespeichers. Die Ladung und Entladung des Speichers seien steuerbar. Dafür wird das Inkrement i_t innerhalb eines Zeitintervalls betrachtet. Es ist $i_t \in [-a_t, a_{max} - a_t]$. In dem Optimierungsproblem wird zwischen einem positiven Inkrement $i_t^+ := \max(i_t, 0)$, welches der Ladung der Batterie, und dem negativen Inkrement $i_t^- := \min(i_t, 0)$, welches der Entladung der Batterie entspricht, unterschieden. Bezeichne l_t den Stromverlust durch die Zwischenspeicherung. In der Modellierung wird er bei der Entladung der Batterie errechnet: $l_t = (1 - \eta_a) i_t^-$. Der Lade- und Entladeprozess i_t der Batterie soll ebenfalls im Hinblick auf die Reduktion der CO₂-Emissionen im Microgrid optimiert werden.

2.3.2.6 Netzbezug und Einspeisung

Sei $p_t \in \mathbb{R}^+$ der vom Verteilernetz gezogene Strom („power“) im Zeitintervall t in kWh und $f_t \in \mathbb{R}^+$ der Strom („fed in“), der vom Microgrid in das Verteilernetz eingespeist wird.

2.3.3 Modellierung der CO₂-Emissionen

Durch den Betrieb des Mikro-BHKWs und der Gasheizung werden Treibhausgasemissionen (Kohlenstoffdioxid, Schwefeldioxid, Methan und Stickstoffoxide) freigesetzt. Wird Strom aus dem Netz importiert, so werden ebenfalls in der vorgelagerten Produktion Treibhausgase emittiert. Die unterschiedlichen Emissionen werden

hinsichtlich ihrer Klimaschädlichkeit vergleichbar, wenn die entsprechenden CO₂-Äquivalente verwendet werden. Die Umrechnungsfaktoren für die CO₂-Äquivalente wurden von einem Expertengremium der Vereinten Nationen abhängig von der Erwärmungswirkung einer bestimmten Menge eines Treibhausgases über einen Zeitraum von 100 Jahre festgelegt (vgl. [34]).

Weitere klimarelevante Emissionen ergeben sich aus vor- und nachgelagerten Prozessketten. Hierzu gibt es kaum belastbare Zahlen. In einer Vergleichsstudie des VDI [35] wird aufgezeigt, dass die Bilanzgrenzen unterschiedlicher Studien deutlich voneinander abweichen. Zudem machen viele Studien keine Angaben zu den CO₂-Äquivalenten, sondern weisen nur die reinen CO₂-Emissionen aus. Dazu gehören u.a. die umfassenden Studien des Bundesumweltamtes zu den Emissionsfaktoren des deutschen Strommixes (vgl. [36, 37]). Da der Emissionsfaktor des Strommixes von wesentlicher Bedeutung für die Bewertung des Microgrids ist, werden in der Analyse einheitlich die direkten CO₂-Emissionen für die Erzeugung einer Kilowattstunde Energie betrachtet. Dazu sei angemerkt, dass der Anteil der CO₂-Emissionen an den CO₂-Äquivalenten mit Abstand am bedeutendsten ist (vgl. [35]).

Der Emissionsfaktor $e_b \in \mathbb{R}^+$ bezeichne die CO₂-Emissionen [g/kWh], die bei der Erzeugung von einer kWh Energie durch das BHKW generiert werden. Dabei hängt e_b wesentlich von dem Emissionsfaktor des verwendeten Brennstoffs ab. Dieser sei in dem modellierten Microgrid Erdgas, welcher bei der Verbrennung ca. 202 g/kWh freisetzt (vgl. [37]). Dieser Wert muss durch den Wirkungsgrad des BHKWs geteilt werden, um den Emissionsfaktor e_b für das BHKW zu erhalten. In der Modellierung wird angenommen, dass die Gasheizung denselben Wirkungsgrad wie das Mikro-BHKW hat und mit demselben Brennstoff betrieben wird. Daher bezeichnet e_b auch die CO₂-Emissionen pro erzeugte kWh Energie der Brennwertgasheizung.

Der Emissionsfaktor des Strommixes wird als e_p (ebenfalls $\in \mathbb{R}^+$) bezeichnet. Dieser gibt die CO₂-Emissionen [g/kWh] an, welche durchschnittlich bei der Erzeugung einer Kilowattstunde Strom für den Endverbrauch emittiert werden. Der Emissionsfaktor hängt von der Zusammensetzung des Strommixes ab und ist aufgrund der Entwicklung hin zu erneuerbaren Energieträgern in den letzten Jahren leicht gesunken (vgl. [37]). Es wird mit dem geschätzten Wert des CO₂-Emissionsfaktor für den inländischen Stromverbrauch für das Jahr 2015 gerechnet. Dieser beträgt 587 g/kWh. In der Abb. 2.2 ist die Entwicklung dieses Wertes über die letzten 25 Jahre dargestellt.

Der CO₂-Emissionsfaktor des BHKWs $e_b = 1/\eta_b \cdot 202 \text{ g/kWh}$ ist damit für jedes BHKW mit einem Wirkungsgrad $\eta_b > 35\%$ kleiner als der modellierte CO₂-Emissionsfaktor des deutschen Strommixes $e_b = 587 \text{ g/kWh}$. Der Wirkungsgrad von Mikro-BHKW beträgt üblicherweise mehr als 90%. Damit kann man auch annehmen, dass $e_b < \eta_a e_p$ gilt. Das bedeutet, dass die Verwendung von Strom, der durch das BHKW erzeugt wurde und in der Batterie zwischengespeichert wird, weniger CO₂-Emissionen verursacht als der Bezug aus dem Verteilernetz, solange die produzierte Wärme ebenfalls genutzt werden kann.




Abbildung 2.2: Spezifische Kohlenstoffdioxid-Emissionen des deutschen Strommixes mit und ohne Berücksichtigung des Stromhandelssaldos. Bei den mit *-markierten Zahlen handelt es sich um vorläufige Werte (Stand 2016). Quelle: Bericht des Umweltbundesamtes zur Entwicklung der CO₂-Emissionen [37].

2.3.4 Modellierung der Betriebskosten

Die laufenden Betriebskosten für die Energieversorgung sind abhängig vom Gaspreis, den Strompreisen, der Einspeisevergütung und den möglichen steuerlichen Vor- und Nachteilen. Dazu kommen feste Betriebskosten wie beispielsweise für die Wartung und die Versicherung der technischen Komponenten. Diese können nicht über das Energiemanagement optimiert werden und werden daher an dieser Stelle nicht betrachtet.

2.3.4.1 Brennstoffkosten

Seien $c_b \in \mathbb{R}^+$ die Brennstoffkosten in Eurocent, die anfallen, um eine kWh Energie (Strom und Wärme im Verhältnis $1 : \varphi_b$) durch das BHKW zu erzeugen. Die Kosten, um eine kWh Wärme durch die Gasheizung zu erzeugen, betragen dann ebenfalls c_b , da angenommen wird, dass die Brennstoffgasheizung und das BHKW denselben Wirkungsgrad η_b haben und den gleichen Brennstoff verwenden.

2.3.4.2 Stromtarife

Es werden drei Arten von Stromtarifen untersucht: (1) ein fester Strompreis, (2) TOU Pricing und (3) RTP Pricing. Sei $c_{p,t} \in \mathbb{R}^+$ der Preis für eine kWh Strom im Intervall t . Es wird angenommen, dass die Brennstoffkosten zur Generation einer kWh Energie durch das Mikro-BHKW zu jeder Zeit günstiger als der Strompreis sind. Dies soll auch gelten, wenn sie im Stromspeicher zwischengespeichert wird; mit anderen Worten, es wird angenommen, dass $c_b < \eta_a c_{p,t}$ für alle t gilt. Dass diese Annahme adäquat ist, wird im Vergleich der durchschnittlichen Strom- und Gaspreise für das zweite Quartal 2015 in Deutschland deutlich: Der durchschnittliche Strompreis betrug 29,51 ct/kWh (vgl. [38]), während der durchschnittliche Gaspreis bei 6,81 ct/kWh (vgl. [39]) lag und c_b bei einem üblichen Wirkungsgrad von $\eta_b = 0.9$ für das Mikro-BHKW mit 7.56 ct/kWh modelliert werden kann.

2.3.4.3 Einspeisevergütung und steuerliche Regelungen

In Deutschland wird die Einspeisung und Vergütung von Strom aus erneuerbaren Energien rechtlich durch das Erneuerbare-Energien-Gesetz (EEG), die Vergütung von Strom, erzeugt durch ein BHKW mit einem nicht-erneuerbaren Brennstoff, durch das Kraft-Wärme-Kopplungsgesetz KWKG) geregelt. Der Vergütungssatz für Solarstrom ist abhängig von der Größe der PV-Anlage und dem Zeitpunkt der Inbetriebnahme. Für eine PV-Anlage mittlerer Größe (10 bis 40 Kilowatt peak (kWp)), welche im ersten Quartal 2016 in Betrieb genommen wurde, wird die Einspeisung mit 11.97 ct/kWh vergütet. Für Mikro-BHKW, welche mit einem nicht-erneuerbaren Brennstoff betrieben werden, entspricht der Vergütungssatz üblicherweise dem KWK-Index, welcher sich aus dem durchschnittlichen Preis für Baseload-Strom des vergangenen Quartals an der Strombörse EEX (European Energy Exchange) berechnet. Für das erste Quartal 2016 lag dieser Wert bei 2,517 ct/kWh. Zusätzlich wird die Ausspeisung mit 8 ct/kWh gefördert⁴. Weiterhin wird der durch das BHKW erzeugte und in das Verteilernetz eingespeiste Strom mit Entgelten für die dezentrale Einspeisung⁵ – ehemals vermiedene Netznutzungsentgelte – durch den Betreiber des Elektrizitätsverteilernetzes vergütet. Zudem werden für BHKW mit einer elektrischen Leistung kleiner als 2 Megawatt, die Energiesteuer⁶ für den Brennstoff und die Stromsteuer⁷ beim Eigenverbrauch erlassen. Der Eigenverbrauch wird ebenfalls nach dem KWKG mit 4 ct/kWh gefördert. Dagegen wird der Eigenverbrauch von PV-Anlagen seit 2014 ab einer gewissen Anlagegröße nach der Neufassung des EEGs besteuert.

Mehr als hundert weitere Länder haben ebenfalls Einspeisevergütungen eingeführt (vgl. [40]). Die sogenannten feed-in Tarife (FIT) sind von landesspezifischen Regeln abhängig und unterscheiden sich erheblich. In [41] werden weltweite Fördermaßnahmen zur Nutzung von Solarstrom analysiert, so gibt es beispielsweise in den

⁴ §7 KWKG

⁵ §18 StromNEV

⁶ §3 EnergieStG

⁷ §9 StromStG

Ländern USA und Kanada ebenfalls finanzielle Anreize, welche an jede produzierte Kilowattstunde Solarstrom gekoppelt sind. Die Analyse ist aus dem Jahr 2011 und teilweise bereits überholt. So hat Spanien beispielsweise seine Fördermaßnahmen zurückgefahren und besteuert seit 2015 den Eigenverbrauch von Solarstrom (vgl. [42]).

Die Unterschiede in den steuerlichen Regelungen und die Tatsache, dass sie oft sehr kurzlebig sind, macht eine allgemeine Berücksichtigung bei der Modellierung schwierig. In der Modellierung sei $c_f \in \mathbb{R}^+$ die Vergütung in Cent, welche sowohl für die Einspeisung von Solarstrom als auch von Strom, erzeugt durch das Mikro-BHKW, angewendet wird. Mögliche steuerliche Erleichterungen für die Erzeugung von regenerativ erzeugtem Strom und Abgaben für die Eigenstromnutzung werden in der Modellierung vernachlässigt. Es wird davon ausgegangen, dass es trotz oder gerade wegen weiterer regulativer Maßnahmen profitabel ist, die CO₂-Emissionen des lokalen Energieverbrauchs zu minimieren.

2.3.5 Optimierungsproblem

Für jeden Tag sollen die Betriebsführung $(b_t)_{t=1,\dots,96}$ des Mikro-BHKWs und, falls vorhanden, die Betriebsführung $(i_t)_{t=1,\dots,96}$ des Stromspeichers unter Einbezug der anderen Komponenten im Microgrid so optimiert werden, dass eine möglichst nachhaltige und wirtschaftlich profitable Energieversorgung erreicht wird. In der Optimierung werden drei Ziele mit absteigender Priorität verfolgt: (1) die Reduktion der CO₂-Emissionen, (2) die Reduktion der Betriebskosten und (3) falls ein fester Strompreis modelliert wird, ein möglichst gleichmäßiger Stromimport zur Vermeidung von Spitzenlasten. Die Betriebsführung des BHKWs und des Stromspeichers hängen dabei teilweise voneinander ab. Daher wird die gemeinsame Betriebsführung $(b_t, i_t)_{t=1,\dots,96}$ gesucht, welche die Ziele umsetzt.

In den meisten wissenschaftlichen Artikeln zum Betrieb von Mikro-BHKW stehen die Betriebskosten im Vordergrund und der Betrieb des BHKW zum Zweck der Stromeinspeisung in das Verteilernetz ist dafür ein Teil des Konzepts. Dies ist in dem vorliegenden Ansatz nicht vorgesehen, da es der Reduktion der CO₂-Emissionen widerspricht, wie im Folgenden noch ausgeführt wird. Um jedoch besser vergleichbar zu sein, wird in einem zusätzlichen weiteren Optimierungsproblem analysiert, welches Potential zur Betriebskostensenkung existiert, wenn Strom auch explizit zum Zweck der Einspeisung erzeugt und in Kauf genommen wird, dass dadurch weitere CO₂-Emissionen erzeugt werden.

2.3.5.1 Reduktion der CO₂-Emissionen

Die CO₂-Emissionen für die Energieversorgung im Microgrid entstehen bei dem Betrieb des Brennwertkessels $(d_t)_{t=1,\dots,96}$ und des Mikro-BHKWs $(b_t)_{t=1,\dots,96}$ und durch den Strombezug $(p_t)_{t=1,\dots,96}$. Für einen Tag berechnen sich die gesamten CO₂-Emissionen wie folgt:

$$\begin{aligned}
 e_{total} &= e_b \sum_{t=1}^{96} d_t + e_b \sum_{t=1}^{96} (\varphi_b + 1) b_t + e_p \sum_{t=1}^{96} p_t \\
 &= \underbrace{e_b \sum_{t=1}^{96} (d_t + \varphi_b b_t)}_{e_{therm.}} + \underbrace{e_b \sum_{t=1}^{96} b_t + e_p \sum_{t=1}^{96} p_t}_{e_{electr.}}.
 \end{aligned} \tag{2.1}$$

Der Anteil $e_{therm.}$ beschreibt die CO₂-Emissionen durch die Wärmeerzeugung und der Anteil $e_{elektr.}$ durch die Stromerzeugung. Die Emissionen des BHKWs werden in dieser Rechnung anteilig der Stromkennzahl aufgeteilt. Zur Reduktion der CO₂-Emissionen werden die Anteile zunächst getrennt betrachtet.

CO₂-Emissionen in der Stromversorgung Es soll $e_{electr.} = e_b \sum b_t + e_p \sum p_t$ unter der Nebenbedingung minimiert werden, dass der Bedarf y_t in jedem Zeitintervall $t \in \{1, \dots, 96\}$ gedeckt ist. Um dies zu modellieren, müssen auch die Solarstromerzeugung $(s_t)_{t=1, \dots, 96}$, die Möglichkeit Strom zu speichern sowie die Kapazitätsgrenzen des BHKWs und des Stromspeichers berücksichtigt werden. Es werden die möglichen Zustände im Microgrid für ein Intervall t betrachtet: Der Betrieb b_t des BHKWs kann auf Null gesetzt oder innerhalb der Grenzen b_{min}, b_{max} gewählt werden:

$$b_t \in [0] \cup [b_{min}, b_{max}]. \tag{2.2}$$

Die Variable a_t beschreibt den Zustand des Stromspeichers zu Beginn des Intervalls t . Der Stromspeicher kann demnach in dem Intervall maximal $a_{max} - a_t$ kWh an Strom aufnehmen und maximal a_t kWh abgeben. Für das Inkrement i_t muss daher gelten:

$$i_t \in [-a_t, a_{max} - a_t]. \tag{2.3}$$

Bei dem Inkrement i_t wird zur Modellierung des Wirkungsgrades η_a und der entsprechenden Energieverluste durch die Speicherung zwischen der positiven Realisierung $i_t^+ := \max(i_t, 0)$, welche der Ladung der Batterie, und der negativen Realisierung $i_t^- := \min(i_t, 0)$, welche der Entladung der Batterie entspricht, unterschieden. Die Energieverluste werden bei der Entladung berechnet. Das heißt, bei einer Entladung um i_t^- werden dem Microgrid $\eta_a i_t^-$ kWh Strom zur Verfügung gestellt. Es ist somit direkt ersichtlich, dass es bzgl. der Reduktion der CO₂-Emissionen unvorteilhaft ist, Strom aus dem Verteilernetz zwischenspeichern. Dies wird in der Betriebsführung des Speichers durch folgende Restriktion direkt ausgeschlossen:

$$i_t^+ \leq \max(b_t + s_t, 0). \tag{2.4}$$

Ein Strombezug in dem Intervall t erfolgt, wenn gemäß der Wahl von b_t und i_t nicht ausreichend Strom im Microgrid zur Verfügung steht:

$$p_t = \max(y_t - s_t - b_t + \eta_a i_t^- + i_t^+, 0). \tag{2.5}$$

Ist dagegen Strom überschüssig, so wird dieser in das Verteilernetz eingespeist:

$$f_t = \max(-y_t + s_t + b_t - \eta_a i_t^- - i_t^+, 0). \quad (2.6)$$

Der Zustand des Stromspeichers zum Ende des Zeitintervalls ist

$$a_{t+1} = a_t + i_t. \quad (2.7)$$

Durch die Wahl von $(b_t)_{t=1,\dots,96}$ und $(i_t)_{t=1,\dots,96}$ gemäß den Bedingungen (2.2) und (2.3) sowie den Gleichungen (2.5) bis (2.7) ist der Stromfluss im Microgrid vollständig beschrieben und sichergestellt, dass der Strombedarf zu jeder Zeit gedeckt ist. Durch die Gleichungen (2.4) und (2.6) ist zudem gewährleistet, dass nur Strom, der durch die PV-Anlage oder das Mikro-BHKW erzeugt wurde, eingespeist wird.

Wird zunächst die gekoppelte Wärmeproduktion außen vor gelassen, dann lautet das Optimierungsproblem zur Minimierung der CO₂-Emissionen in der Stromversorgung:

$$\begin{aligned} & \min_{(b_t, i_t)} \sum_{t=1}^{96} e_b b_t + e_p p_t, \\ & \text{unter den Nebenbedingungen} \\ & b_t \in [0] \cup [b_{min}, b_{max}], \\ & i_t \in [-a_t, \min(a_{max} - a_t, \max(b_t + s_t, 0))], \\ & a_{t+1} = a_t + i_t, \\ & p_t = \max(y_t - s_t - b_t + \eta_a i_t^- + i_t^+, 0) \quad \forall t \in \{1, \dots, 96\}. \end{aligned} \quad (2.8)$$

CO₂-Emissionen in der Wärmeversorgung Für die Minimierung der CO₂-Emissionen in der Wärmeversorgung $e_{therm.} = e_b \sum (d_t + \varphi_b b_t)$ ist es unerheblich, ob die Wärme durch das BHKW oder den Brennwärtekessel erzeugt wird, solange der Wärmebedarf über den Lauf des Tages gedeckt wird. Der kleinste Wert für $e_{therm.}$ wird angenommen, wenn der Wärmebedarf der Erzeugung entspricht und damit folgende Gleichung gilt

$$\sum_{t=1}^{96} d_t + \sum_{t=1}^{96} \varphi_b b_t = \sum_{t=1}^{96} h_t. \quad (2.9)$$

Daraus leiten sich folgende notwendige Bedingungen für den Betrieb des Mikro-BHKW ab:

$$\sum_{t=1}^{96} \varphi_b b_t \leq \sum_{t=1}^{96} h_t, \quad (2.10)$$

$$\sum_{t=1}^{96} \varphi_b b_t \geq \sum_{t=1}^{96} h_t - \sum_{t=1}^{96} d_{max}. \quad (2.11)$$

Es wird angenommen, dass für jede Betriebsführung $(b_t)_{t=1,\dots,96}$, welche die Gleichungen (2.10) und (2.11) erfüllt, eine Betriebsführung des $(d_t)_{t=1,\dots,96}$ des Brennwertkessels gefunden wird, so dass zum einen (2.9) gilt und zum anderen unter Einbezug des Warmwasserspeichers der Wärmebedarf in jedem Zeitintervall gedeckt werden kann. Der Warmwasserspeicher sei dafür groß genug gewählt. Wärmeverluste durch eine mögliche Zwischenspeicherung werden vernachlässigt.

Gesamte CO₂-Emissionen Für die Optimierung von e_{total} werden die Überlegungen zu der Betriebsführung des BHKWs zusammengeführt: Die Emissionen in der Wärmeversorgung können minimiert werden, wenn $(b_t)_{t=1,\dots,96}$ die Gleichungen (2.10) und (2.11) erfüllt. Auf diese Weise wird gewährleistet, dass keine überschüssige Wärme produziert und gleichzeitig die Wärmeversorgung unter Einbezug des Brennwertkessels und des Warmwasserspeichers sichergestellt wird. Diese Bedingungen werden in der Optimierung von $e_{electr.}$ aufgenommen. Das resultierende Optimierungsproblem lautet dann

$$\begin{aligned}
 & \min_{(b_t, i_t)} \sum_{t=1}^{96} e_b b_t + e_p p_t, \\
 & \text{unter den Nebenbedingungen} \\
 & \quad b_t \in [0] \cup [b_{min}, b_{max}], \\
 & \quad i_t \in [-a_t, \min(a_{max} - a_t, \max(b_t + s_t, 0))], \\
 & \quad a_{t+1} = a_t + i_t, \\
 & \quad p_t = \max(y_t - s_t - b_t + \eta_a i_t^- + i_t^+, 0) \quad \forall t \in \{1, \dots, 96\}, \\
 & \text{und} \quad \sum_{t=1}^{96} b_t \leq \frac{1}{\varphi_b} \sum_{t=1}^{96} h_t, \\
 & \quad \sum_{t=1}^{96} b_t \geq \frac{1}{\varphi_b} \left(\sum_{t=1}^{96} h_t - \sum_{t=1}^{96} d_{max} \right). \tag{2.12}
 \end{aligned}$$

Mit anderen Worten wird die gemeinsame Betriebsführung des BHKWs und des Stromspeichers $(b_t, i_t)_{t=1,\dots,96}$ gesucht, welche die CO₂-Emissionen in der Stromversorgung unter Nebenbedingungen minimiert, welche gewährleisten, dass keine überschüssige Wärme produziert wird und gleichzeitig die Wärmeversorgung unter Einbezug des Brennwertkessels und des Warmwasserspeichers sichergestellt werden kann.

2.3.5.2 Reduktion der Betriebskosten

Als zweites Optimierungsziel sollen die laufenden Betriebskosten unter der Bedingung minimiert werden, dass ein Minimum in (2.12) angenommen wird. Betrachtet man hierfür analog zu den CO₂-Emissionen die Betriebskosten für die Strom- und Wärmeversorgung zunächst getrennt, so stellt man fest, dass die Berechnung erhebliche Parallelen aufweist. Dies wird in der Optimierung ausgenutzt.

Betriebskosten der Wärmeversorgung Die Betriebskosten für die Wärmeversorgung im Microgrid setzen sich aus Brennstoffkosten des BHKWs und des Brennwertkessels zusammen. Die Kosten zur Erzeugung einer kWh Wärme ist in beiden Fällen c_b . Daher berechnen sich die Kosten aus:

$$c_{therm.} = \sum_{t=1}^{96} c_b(d_t + \varphi_b b_t).$$

Kostentechnisch ist es irrelevant, ob die Wärme durch das BHKW oder den Brennwertkessel erzeugt wird. Wird eine Betriebsführung des BHKWs gewählt, so dass ein Minimum in (2.12) angenommen wird und damit auch die Gleichungen (2.10) und (2.11) gelten, so werden die Betriebskosten für die Wärmeversorgung bei einer entsprechenden Betriebsführung des Brennwertkessels $d(t)_{t=1\dots,96}$ ebenfalls minimiert.

Betriebskosten der Stromversorgung Die laufenden Kosten für die Stromversorgung im Microgrid setzen sich aus den Betriebskosten des BHKWs und den Kosten für den Netzbezug zusammen. Davon abzuziehen sind Vergütungen für den eingespeisten Strom:

$$c_{electr.} = \sum_{t=1}^{96} c_b b_t + c_{p,t} p_t - c_f f_t. \quad (2.13)$$

Dieser Term soll minimiert werden, solange die Minimierung von (2.12) gewährleistet bleibt. Die Berechnungen von $c_{electr.}$ und $e_{electr.}$ unterscheiden sich in den Parametern c_b , $c_{p,t}$ und e_b , e_p sowie dem Term $\sum c_f f_t$. Eine Erhöhung von $\sum f_t$ impliziert eine Erhöhung von $\sum b_t$ oder eine indirekte Erhöhung von $\sum p_t$ durch die Wahl von i_t nach den Gleichungen (2.2)-(2.5), wodurch sich $e_{electr.}$ erhöht. Damit die Minimierung von (2.12) gewährleistet bleibt, muss in der Minimierung der Betriebskosten dieser Effekt ausgeschlossen werden und es wird nur der folgende Term betrachtet

$$\sum_{t=1}^{96} c_b b_t + c_{p,t} p_t. \quad (2.14)$$

Zur weiteren Analyse wird unterschieden, ob ein fester Strompreis vorliegt oder variable Strompreise.

Fall 1: Fester Strompreis. Ist der Strompreis fest, d.h. die Strompreise $c_{p,t}$ nehmen für jedes Zeitintervall t den gleichen Wert c_p an, und es gilt die Annahme aus Abschnitt 2.3.4, dass $c_b < \eta_a c_p$ ist, dann entspricht dies der Struktur der Emissionsfaktoren, für welche $e_b < \eta_a e_p$ gilt. Eine Minimierung von (2.14) unter den Nebenbedingungen von (2.12) entspricht daher einer Optimierung von (2.12). Mit anderen Worten werden die Betriebskosten durch die vorgestellte Optimierung der CO₂-Emissionen bereits soweit gesenkt, dass darüber hinaus keine weitere Reduktion möglich ist, ohne die Bedingungen von (2.12) zu verletzen.

Fall 2: Variable Stromtarife. Ist der Strompreis nicht fest, beinhaltet die Minimierung von (2.14) das Potential, den nicht vermeidbaren Stromimport so zu

steuern, dass er in Zeiten erfolgt, in welchen die Strompreise niedrig sind. Um sicherzustellen, dass bei einer Minimierung von (2.14) auch ein Minimum in (2.12) angenommen wird, wird die Struktur der Kostenparameter mit der Struktur der Emissionsfaktoren verglichen. Es kann gemäß der Erläuterungen in Abschnitt 2.3.4 angenommen werden, dass $c_b < \eta_a c_{p,t}$ für alle t gilt. Damit bleibt der Vorzug des BHKW-Betriebs gegenüber dem Stromimport erhalten. Allerdings kann es durch die unterschiedlichen Strompreise $c_{p,t}$ lukrativ sein, in einem Intervall t durch das BHKW erzeugten Strom zwischenzuspeichern, obwohl er in diesem Intervall lokal genutzt werden könnte und durch diesen Schritt in dem Intervall t Strom importiert werden muss. Dies ist der Fall, wenn durch die Nutzung des gespeicherten Stroms in einem späteren Zeitintervall s mit $\eta_b c_{p,s} > c_{p,t}$ dafür weniger Strom importiert werden muss. Dieser Fall kann bei einem festen Strompreis c_p oder analog bei der Optimierung von (2.12) mit einem festen Emissionfaktor e_p nicht eintreten. Vielmehr erhöhen sich durch eine solche Aktion die CO₂-Emissionen. Um dies in der Optimierung von (2.14) auszuschließen, wird eine zusätzliche Bedingung für die Regulation des Stromspeichers i_t aufgenommen: In einem Intervall t darf nur Strom gespeichert werden, der lokal erzeugt ist und der in dem Zeitintervall selbst nicht genutzt werden kann, d.h.

$$i_t^+ \leq \max(b_t + s_t - y_t, 0). \quad (2.15)$$

Diese Bedingung wird in der Minimierung von (2.12) immer implizit erfüllt. Wird sie in der Minimierung von $e_{electr.}$ neben den bereits genannten Nebenbedingungen berücksichtigt, so wird zugleich ein Minimum in (2.12) angenommen. Das Optimierungsproblem bei variablen Stromtarifen lautet demnach

$$\begin{aligned} & \min_{(b_t, i_t)} \sum_{t=1}^{96} c_b b_t + c_{p,t} p_t, \\ & \text{unter den Nebenbedingungen} \\ & \quad b_t \in [0] \cup [b_{min}, b_{max}], \\ & \quad i_t \in [a_t, \min(a_{max} - a_t, \max(b_t + s_t - y_t, 0))], \\ & \quad a_{t+1} = a_t + i_t, \\ & \quad p_t = \max(y_t - s_t - b_t + \eta_a i_t^- + i_t^+, 0) \quad \forall t \in \{1, \dots, 96\}, \\ & \text{und den Gleichungen (2.10) und (2.11).} \end{aligned} \quad (2.16)$$

2.3.5.3 Reduktion von Spitzenlasten

Wenn einer fester Strompreis vorliegt, soll als drittrangiges Ziel der verbleibende Stromimport geglättet werden. Dafür wird p_t in der $\|\cdot\|_2$ -Norm, bzw. im Quadrat der Norm unter der Nebenbedingung minimiert, dass ein Minimum für (2.12)

angenommen wird:

$$\min_{\{b_t, i_t\}} \sum_{t=1}^{96} p_t^2 \quad (2.17)$$

unter den Nebenbedingungen

$$p_t = \max(y_t - s_t - b_t^* + \eta_a i_t^{*+} + i_t^{*-}, 0)$$

und $(b_t, i_t)^* = \arg \min_{(b_t, i_t)} \text{ von (2.12).}$

2.3.5.4 Alternative Zielsetzung

In dem beschriebenen Ansatz wird die Einspeisung von Strom vermieden, wenn der Strom lokal verwendet werden kann oder wenn durch die Bereitstellung weitere CO₂-Emissionen entstehen. Dies ist bedingt durch die Zielsetzung, die CO₂-Emissionen zu reduzieren, welche durch die Energieversorgung des Microgrids entstehen. Letztlich bewirkt jedoch auch die Einspeisung von Strom, der durch erneuerbare Energien oder KWK-Kopplung erzeugt wird, eine Senkung der CO₂-Emissionen, da somit – in geringem Maße – der Emissionsfaktor des Strommixes gesenkt wird.

Im Folgenden soll die Zielsetzung dahingehend gelockert werden, dass CO₂-Emissionen in Kauf genommen werden, die durch die Bereitstellung von Strom verursacht werden, der in das Verteilernetz eingespeist wird. Das bietet neuen Spielraum in der Optimierung der Betriebskosten. Für variable Strompreise wird dafür in der Simulation zusätzlich zu (2.16) das folgende Optimierungsproblem gelöst:

$$\min_{(b_t, i_t)} \sum_{t=1}^{96} c_b b_t + c_{p,t} p_t - c_f f_t \quad (2.18)$$

unter den Nebenbedingungen (2.16).

Für einen festen Strompreis wird zusätzlich das Optimierungsproblem (2.17) unter der alternativen Nebenbedingung gelöst, dass

$$(b_t, i_t)^* = \arg \min_{(b_t, i_t)} \sum_{t=1}^{96} c_b b_t + c_p p_t - c_f f_t \quad (2.19)$$

unter den Nebenbedingungen (2.12).

2.3.6 Betriebsmodus

Durch die Lösung des Optimierungsproblems (2.17) bei einem festen Strompreis, bzw. die Lösung von (2.16) bei variablen Strompreisen erhält man eine Betriebsführung $(b_t, i_t)_{t=1, \dots, 96}^*$, welche unter der Annahme optimal ist, dass die Prognosen für Stromverbrauch, Solarstromerzeugung und Wärmebedarf exakt sind. Um auch bei fehlerbehafteten Prognosen eine vorteilhafte Betriebsführung zu erlangen, werden aus der berechneten Lösung von (2.17), bzw. von (2.16) Handlungsempfehlungen

für den Betrieb abgeleitet, welche dann abhängig von den tatsächlich eintretenden Zuständen im Microgrid umgesetzt werden. Da sich die Optimierung bei variablen Strompreisen wesentlich von der Optimierung bei einem festen Strompreis mit der zusätzlichen Zielsetzung, den Stromimport zu glätten, unterscheidet, werden jeweils unterschiedliche Handlungsempfehlungen abgeleitet.

Im Folgenden bezeichne $(b_t^*)_{t=1,\dots,96}$ die aus der Optimierung berechnete Betriebsführung des BHKWs und $(i_t^*)_{t=1,\dots,96}$ die Betriebsführung des Stromspeichers.

2.3.6.1 Unter variablen Strompreisen

Bestimmung der Handlungsempfehlungen Aus den Werten der Optimierung werden für jedes Zeitintervall Betriebsmodi für das BHKW festgelegt. Dazu werden Kontrollvariablen $v_{b1,t}$, $v_{b2,t}$ und $v_{a,t}$ für jedes Zeitintervall t wie folgend bestimmt:

$$v_{b1,t} = \begin{cases} 0, & \text{wenn } b_t^* = 0, \\ 1, & \text{wenn } b_{\min} \leq b_t^* < u_t < b_{\max}, \\ 2, & \text{wenn } b_t^* = \max(u_t, b_{\min}), \\ 3, & \text{wenn } \max(u_t, b_{\min}) < b_t^* \leq b_{\max}. \end{cases} \quad (2.20)$$

$$v_{b2,t} = \begin{cases} \max(b_{\max}, u_t) - b_t^*, & \text{wenn } v_{b1,t} \in \{0, 1\}, \\ 0, & \text{sonst.} \end{cases} \quad (2.21)$$

$$v_{a,t} = \min(\max(v_{a,t+1} + u_t, 0), a_{\max}). \quad (2.22)$$

wobei $u_t := y_t - s_t$ und $v_{a,96} = a_{\max}$ sei. Der Hilfswert $v_{a,t}$ beschreibt den maximal zulässigen Akkustand durch eine Ladung des BHKWs im Zeitintervall t , so dass der prognostizierte Überschuss an Solarenergie im Stromspeicher noch aufgenommen werden kann. Für die Optimierung unter variablen Strompreisen werden zwei weitere Variablen v_c und v_{t_c} zur Entladung der Batterie abhängig vom Strompreis bestimmt:

$$v_c = \max_{t \in 96} \{c_{p,t} : p_t > 0\}, \quad (2.23)$$

$$v_{t_c} = \max \{t : c_{p,t} = v_c \wedge p_t > 0\}. \quad (2.24)$$

Umsetzung der Handlungsempfehlungen Aus den Kontrollvariablen wird der Betrieb abhängig von der aktuellen Situation im Microgrid berechnet. Die Kalkulation erfolgt in kW. Sei \tilde{t} ein Zeitpunkt im Zeitintervall t , sei $\tilde{y}_{\tilde{t}}$ der Strombedarf, $\tilde{s}_{\tilde{t}}$ die Solarstromerzeugung und $\tilde{u}_{\tilde{t}} = \tilde{y}_{\tilde{t}} - \tilde{s}_{\tilde{t}}$ die Differenz zum Zeitpunkt \tilde{t} in kW. Die Werte seien Durchschnittswerte für einen gewissen Zeitraum (15-Minuten-Intervalle in der Simulation). Die elektrische Leistung des BHKWs $\tilde{b}_{\tilde{t}}$ wird wie folgt moduliert:

$$\tilde{b}_{\tilde{t}} = \begin{cases} 0, & \text{wenn } v_{b1,t} = 0 \vee v_{a,t} < a_t, \\ \min(\max(\tilde{u}_{\tilde{t}} - 4v_{b2,t}, 4b_{\min}), 4b_{\max} - 4v_{b2,t}), & \text{wenn } v_{b1,t} = 1, \\ \min(\max(\tilde{u}_{\tilde{t}}, 4b_{\min}), 4b_{\max}), & \text{wenn } v_{b1,t} = 2, \\ 4b_{\max}, & \text{wenn } v_{b1,t} = 3. \end{cases}$$

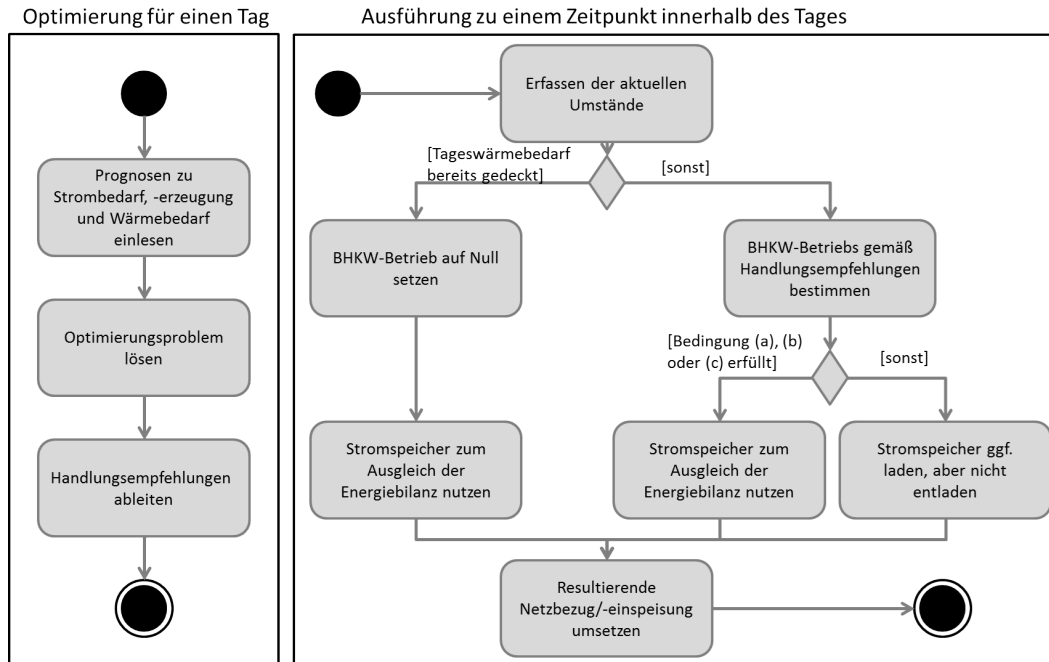


Abbildung 2.3: Aktivitätsdiagramme zur Betriebsführung bei variablen Strompreisen: links zur Berechnung der Handlungsempfehlungen durch das Lösen des Optimierungsproblems für einen ganzen Tag; rechts zur Bestimmung des Betriebes des BHKWs und des Stromspeichers zu einem Zeitpunkt innerhalb des Tages.

Darüber hinaus wird die Produktion des BHKWs auf Null gesetzt, wenn der Tagesbedarf an Wärme zum Zeitpunkt \tilde{t} bereits erbracht ist. Wird der Strombedarf des Microgrids nicht durch das BHKW gedeckt, so wird in den folgenden Fällen der Stromspeicher entladen:

- (a) Der Ladezustand des Stromspeicher ist größer als der Grenzwert zum Zeitpunkt t , d.h. $a_t > v_{a,t}$.
- (b) Der Strompreis $c_{p,t}$ ist größer als der Grenzwert v_c .
- (c) Der Strompreis $c_{p,t}$ entspricht v_c und $t \geq c_t$.

Darüber hinaus bestehender Strombedarf wird von dem Verteilernetz bezogen. Wird durch das BHKW oder die Solaranlage mehr Strom erzeugt, als direkt verwendet werden kann, so wird dieser, sofern Kapazitäten frei sind, in der Batterie gespeichert. Darüber hinaus bestehende Überschüsse werden in das Verteilernetz eingespeist. Die Arbeitsvorgänge zur Bestimmung der Betriebsführung sind in den Aktivitätsdiagrammen in Abb. 2.3 visualisiert.

2.3.6.2 Unter festem Strompreis mit Spitzenlastvermeidung

Bestimmung der Handlungsempfehlungen Zur Bestimmung der Betriebsführung werden ebenfalls die Hilfsvariablen $v_{b1,t}$, $v_{b2,t}$ und $v_{a,t}$ für jedes Zeitintervall t aus den Werten der Optimierung gemäß der Gleichungen (2.20), (2.21) und (2.22) bestimmt. Darüber hinaus wird die Spitzenlast p_{max} in der Optimierung notiert:

$$p_{max} = \max_t p_t. \quad (2.25)$$

Umsetzung der Handlungsempfehlungen Aus den berechneten Kontrollvariablen wird ähnlich wie für den Betrieb unter variablen Energiepreisen der Betrieb abhängig von der Situation im Microgrid berechnet. Die Kalkulation erfolgt ebenfalls in kW. Sei \tilde{t} im Zeitintervall t , sei wie zuvor $\tilde{y}_{\tilde{t}}$ der Strombedarf, $\tilde{s}_{\tilde{t}}$ die Solarstromerzeugung und $\tilde{u}_{\tilde{t}} = \tilde{y}_{\tilde{t}} - \tilde{s}_{\tilde{t}}$ die Differenz zum Zeitpunkt \tilde{t} in kW. Die Werte sind Durchschnittswerte für einen gewissen Zeitraum. In der Simulation werden die Durchschnittswerte für 15 Minuten-Intervalle verwendet. Die elektrische Leistung des BHKWs $\tilde{b}_{\tilde{t}}$ wird dann, wie folgt, moduliert:

$$\tilde{b}_{\tilde{t}} = \begin{cases} 0, & \text{wenn } v_{a,t} < a_t, \\ \min(\max(\tilde{u}_{\tilde{t}} - 4 \min(v_{b2,t}, p_{max}), 0), 4b_{max}), & \text{wenn } v_{b1,t} = 1, \\ \min(\max(\tilde{u}_{\tilde{t}} - 4 \min(v_{b2,t}, p_{max}), b_{min}), 4b_{max}), & \text{wenn } v_{b1,t} = 0, \\ \min(\max(\tilde{u}_{\tilde{t}}, 4b_{min}), 4b_{max}), & \text{wenn } v_{b1,t} = 2, \\ 4b_{max}, & \text{wenn } v_{b1,t} = 3. \end{cases}$$

Darüber hinaus wird die Produktion des BHKWs auf Null gesetzt, wenn der Tagesbedarf an Wärme zum Zeitpunkt \tilde{t} bereits erbracht ist. Wird der Strombedarf nicht durch das BHKW und die Solaranlage gedeckt und es ist gespeicherter Strom verfügbar, so wird der Stromspeicher zur Balancierung der Energiebilanz verwendet. Er wird entladen, wenn die gespeicherte Strommenge den berechneten Grenzwert für diesen Zeitpunkt übertrifft oder wenn der resultierende Netzbezug größer als p_{max} wäre. In letzterem Fall wird nur soviel Strom entladen, dass der Netzbezug nicht die berechnete Spitzenlast p_{max} übersteigt. Das (negative) Inkrement des Stromspeichers wird daher mit folgender (negativer) Leistung berechnet:

$$\tilde{i}_{\tilde{t}}^- = \begin{cases} 0, & \text{wenn } a_t = 0, \\ \eta_a(\min(\tilde{b}_{\tilde{t}} - \tilde{u}_{\tilde{t}}, 0)), & \text{wenn } v_{a,t} < a_t, \\ \eta_a(\min(\tilde{b}_{\tilde{t}} + p_{max} - \tilde{u}_{\tilde{t}}, 0)), & \text{sonst.} \end{cases}$$

Darüber hinaus bestehender Strombedarf wird von dem Verteilernetz bezogen. Wird durch das BHKW oder die Solaranlage mehr Strom erzeugt, als direkt verwendet werden kann, so wird dieser, sofern Kapazitäten frei sind, in der Batterie gespeichert. Darüber hinaus bestehende Überschüsse werden in das Verteilernetz eingespeist.

2.4 Simulation

Zur Evaluation des Betriebsmodus werden zwei Microgrids und drei Energietarife modelliert. Der neue Betriebsmodus wird jeweils für knapp ein Jahr für jeden Tag des Modells simuliert. Die Ergebnisse werden in Kennzahlen festgehalten, mit welchen die Effekte auf die CO₂-Emissionen und die Betriebskosten der Energieversorgung ersichtlich sind. Dabei werden die Microgrids mit unterschiedlicher Ausstattungen simuliert, um zu sehen, welche Bedeutung die Existenz von PV-Anlagen, bzw. einem Stromspeicher auf die Energieversorgung im Microgrid haben.

Um zudem zu prüfen, welche Auswirkung ungenaue Prognosen auf die Energiebilanz des Microgrids haben, werden in einer Robustheitsanalyse der Strombedarf, der Wärmebedarf und die Solarstromerzeugung mit gewissen Fehlerraten gegenüber den Inputparametern des Optimierungsproblems modelliert.

2.4.1 Spezifikation der Komponenten

2.4.1.1 Modell 1

Der Strombedarf und Wärmebedarfs des ersten Modells werden anhand der durchschnittlichen Verbrauchswerte für 16 2-Personenhaushalte simuliert. Nach dem Bundesverband der Energie- und Wasserwirtschaft (BDEW) beträgt der typische Strombedarf eines 2-Personenhaushalts ohne elektrische Warmwasserbereitung 3000 kWh im Jahr (vgl. [43]). Die Verbrauchskurve der Lastprofile wird durch die standardisierten Lastprofile eines Verteilernetzbetreibers nach BDEW modelliert (vgl. [44]). Dabei wird mithilfe einer Dynamisierungsfunktion zwischen Werktagen, Samstagen und Sonntagen sowie den Jahreszeiten unterschieden. Der durchschnittliche Heizbedarf hängt von der Wohnfläche und dem Heizwärmebedarf ab. Es wird mit einem jährlichen Heizwärmebedarf von 55 kWh/m² gerechnet. Das entspricht dem Niederenergiehausstandard in Deutschland, der nach der Energieeinsparverordnung bei Neubauten eingehalten werden muss⁸. Die Wohnfläche der 16 Wohnungen wird mit der Durchschnittsgröße von 2-Personenhaushalten in Deutschland, mit 97 m² pro Wohnung, modelliert (vgl. [45]). Die Veränderung des Heizwärmebedarfs im Jahresverlauf wird nach Richtlinien des Verein Deutscher Ingenieure (VDI) [46] modelliert. Dazu kommt der Warmwasserbedarf, der mit 1150 kWh pro Jahr, dem Durchschnittswert eines 2-Personenhaushalt, gemäß [43], kalkuliert wird. Die Bedarfswerte werden für den Zeitraum von 04. Juni 2014 bis zum 19. Mai 2015 modelliert. Dies entspricht dem Zeitraum, für den empirische Daten im Modell 2 vorliegen. Das Verhältnis des Strom- und Wärmebedarfs variiert im Laufe des Jahres erheblich. Die Werte sind in Abb. 2.4 visualisiert. Dabei sind die unterschiedlichen Anforderungen an die Energieversorgung im Laufe des Jahres deutlich erkennbar.

Die installierte Leistung der PV-Anlage wird mit 18 kWp modelliert. Zur Berechnung des Ertrags wird die Sonneneinstrahlung einer Stadt in der Mitte Deutschlands betrachtet und dafür beispielhaft die Werte für die schöne Universitätsstadt Hildes-

⁸ vgl. Energieeinsparverordnung EnEV




Abbildung 2.4: Monatliche Strom- und Wärmebedarfe der modellierten Microgrids, Modell 1 beruht auf Standardlastkurven, Modell 2 wird mit empirisch aufgezeichneten Daten simuliert.

heim herangezogen. Die Strahlungswerte und der Ertrag der Solaranlage werden mithilfe des geographischen Informationssystems PVGIS des Joint Research Center der europäischen Kommission berechnet. Die Solaranlage sei nach Süden ausgerichtet und mit einer Neigung von 36% angebracht. Der Jahresertrag liegt dann bei durchschnittlich 887,33 kWh/kWp. In der Simulation werden die durchschnittlichen Tagesverläufe für jeden Monat gemäß der Simulation von PVGIS verwendet.

Die Größe des BHKWs wird in Abhängigkeit des Strombedarfs gewählt. Es müsste eine elektrische Leistung von ca. 5 kW erbringen, um etwa 90% des Strombedarfs eines Wintertages abzudecken, wenn es ununterbrochen unter Volllast gefahren wird. Für die Modellierung wurden Werte eines Mikro-BHKWs verwendet, welches derzeit auf dem Markt verfügbar ist: das ecoPower 4.7 von Vallaint. Es hat einen modulierenden Gas-Verbrennungsmotor, dessen elektrische Leistung stufenlos zwischen 1,5 und 4,7 kW moduliert werden kann. Die thermische Leistung liegt zwischen 4,7 und 13,8 kW. Das Verhältnis von elektrischer zu thermischer Leistung bleibt nach Angaben des Herstellers über den gesamten Leistungsbereich nahezu konstant und wird mit 1:3 modelliert. Der gesamte Wirkungsgrad beträgt mehr als 90%. Für die Simulation wird von 90% ausgegangen.

Die Größe des Brennwertkessels wird gemäß der Heizlastermittlung nach der VDI-Richtlinie 2067 bestimmt, indem der Wärmebedarf durch die durchschnittliche Anzahl von Volllaststunden von Heizungssystemen in der Region geteilt wird. Dies sind ca. 2150 Volllasten für ein Mehrfamilienhaus in Nord-, bzw. Mitteldeutschland gemäß den Umrechnungsfaktoren der Richtlinie. Demnach liegt die angemessene Leistung einer Heizung bei 40 kW. Da das BHKW bereits 13,8 kW erbringen kann, wird der Brennwertkessel mit 28 kW modelliert. Der Warmwasserspeicher wird mit einer Größe von 1500 l modelliert. Die Wahl der Kapazität orientiert sich an der

Tabelle 2.1: Übersicht der Komponenten in den Microgrid Modellen 1 und 2. Die mit einem * markierten Komponenten sind optional.

	Modell 1	Modell 2
Strombedarf	16 2-Personen-Haushalte, Standardlastprofile	12 Haushalte, REFIT Datensatz
Wärmebedarf	entsprechende Durchschnittswerte	Werte aus Modell 1
Solaranlage*	18 kWp	18 kWp
BHKW*	1.5-4.7 kW _{el}	1.5-4.7 kW _{el}
Stromspeicher*	7/ 13 kWh	7/ 13 kWh
Gasheizung	28/40 kW	28/ 40 kW
Wärmespeicher	1500l	1500l

Förderung durch das Bundesamt für Wirtschaft und Ausfuhrkontrolle (BAFA) für Wärmespeicher von KWK-Anlagen: Diese werden gefördert, wenn das Speichervolumen mindestens 300l pro Kilowatt der installierten elektrischen Leistung des angeschlossenen BHKWs beträgt [47]. Dies sind 1410 Liter. Für die Modellierung wird dieser Wert auf 1500l aufgerundet. Dies entspricht einem Speicherumfang von ca. 85 kWh. Die Kapazität des Stromspeichers wird mit 13 kWh modelliert. Auf diese Weise kann das BHKW an einem Wintertag fast stetig unter Volllast gefahren werden, ohne dass Strom in das Netz eingespeist werden muss. Wird nur eine Solaranlage, aber kein BHKW im Microgrid modelliert, wird die Größe des Speicher auf 7 kWh reduziert, da weniger Strom zwischengespeichert werden muss. Eine Übersicht der Komponenten ist in Tabelle 2.1 dargestellt.

2.4.1.2 Modell 2

Der Strombedarf des zweiten Modells wird durch die Datenaufzeichnung des Stromverbrauchs des REFIT Projekts (REFIT: Personalised Retrofit Decision Support Tools for UK Homes using Smart Home Technology project) [48] simuliert. Der Datensatz umfasst den Stromverbrauch von 20 Wohnungen in Großbritannien in 15 Minuten-Intervallen. Die Aufzeichnungen von zwölf Häusern (2, 3, 4, 6, 7, 10, 11, 15, 17, 18, 19 und 20) werden zur Modellierung des Strombedarfs verwendet, da in diesen Haushalten keine elektrische Warmwasserbereitung verwendet wurde und der Umfang des gesamten Stromverbrauch ungefähr dem aus Modell 1 entspricht, wodurch die Resultate der beiden Modelle gut verglichen werden können. Der Datensatz umfasst 340 Tage, beginnend am 04. Juni 2014.

Bei dem REFIT Projekt wurde auch der Gasverbrauch aufgezeichnet. Diese Daten sind derzeit⁹ leider noch nicht verfügbar. Da die Wohnflächen der Haushalte

⁹ Stand Juni 2016

überdies unbekannt sind, wird der Jahreswärmeverbrauch wie im Modell 1 modelliert. Der monatliche Strom- und Wärmebedarf ist über den Jahresverlauf in Abb. 2.4 dargestellt.

Die weiteren Komponenten des Microgrids werden wie in Modell 1 modelliert. Eine Übersicht ist in Tabelle 2.1 gegeben.

2.4.2 Spezifikation der Betriebskosten

Die Brennstoffkosten des BHKWs und der Gasheizung werden anhand des durchschnittlichen Gaspreises in Deutschland in der zweiten Jahreshälfte 2015 berechnet. Er beträgt 6,81 ct/kWh (vgl. [39]). Die Brennstoffkosten werden daher mit $c_b = \eta_b \cdot 6,81 \approx 7,57$ ct/kWh modelliert.

Für den Stromtarif werden drei Szenarien implementiert: Ein fester Strompreis, Nieder- und Hochlasttarife sowie Real Time Pricing. Im ersten Fall wird angenommen, dass der Preis für eine kWh Strom, $c_{p,t}$, einen konstanten Wert c_p über den gesamten Simulationszeitraum annimmt. Für die explizite Berechnung der Betriebskosten wird der durchschnittliche Preis in Deutschland in der zweiten Jahreshälfte 2015 verwendet: $c_p = 29,51$ ct/kWh (vgl. [38]).

Nieder- und Hochlasttarife sind ein Beispiel für ein zweistufiges TOU Pricing. Für die Modellierung wird angenommen, dass die Strompreise zu den Niedertarifzeiten um 20% geringer sind als in den Hochlastzeiten. Die Niederlastzeiten liegen dabei zwischen 22:00 Uhr und 6:00 Uhr. In der expliziten Berechnung wird der Strompreis zu Hochlastzeiten auf 29,51 ct/kWh gesetzt und der Strompreis zu Niederlastzeiten entsprechend auf 23,61 ct/kWh.

Die Strompreise des RTP sind üblicherweise abhängig von den Handelsdaten an der Strombörse. In diesem Modell wird davon ausgegangen, dass sie mit den Day-Ahead Auction des Spotmarktes der Europäischen Strombörse (EPEX SPOT SE) verknüpft und einen Tag im Voraus bekannt gemacht werden. Dazu wurden die Handelspreise für den entsprechenden Zeitraum der Homepage der EPEX SPOT SE¹⁰ entnommen und mit einem Faktor von 7 multipliziert, da die Handelspreise an der Börse um ein Vielfaches kleiner sind als haushaltsübliche Strompreise. Zudem wird ausgeschlossen, dass der Strompreis einen niedrigeren Wert als die Einspeisevergütung annehmen kann und der Strompreis daher auf minimal 12,5 ct/kWh gesetzt. Der durchschnittliche Strompreis beträgt somit 26,38 ct/kWh.

Die Einspeisevergütung für Solarstrom betrug 11,97 ct/kWh im letzten Quartal 2015. Der KWK-Index in diesem Quartal betrug 3,319 ct/kWh, wobei die Einspeisung zusätzlich mit 8 ct/kWh gefördert wird. In der Modellierung wird konservativ mit einem leicht niedrigeren Wert von $c_f = 11$ ct/kWh gerechnet. Eine Übersicht der modellierten Betriebskosten ist in Tab. 2.2 gegeben.

¹⁰ <https://www.epexspot.com/en/market-data>

Tabelle 2.2: Spezifikation der Betriebskosten im Microgrid

Betriebskosten	
BHKW und Gasheizung:	
Brennstoffkosten	$c_b = 7.57 \text{ ct/kWh.}$
Stromimport:	
fester Strompreis	$c_{p,t} = c_p = 29.51 \text{ ct/kWh } \forall t.$
Nieder-, Hochlasttarif	$c_{p,t} = \begin{cases} 29.51 \text{ ct/kWh,} & \text{wenn } 24 \leq t < 88, \\ 23.61 \text{ ct/kWh,} & \text{sonst.} \end{cases}$
Real Time Pricing	$c_{p,t}$ wird aus den Werten der Day-Ahead-Auktion der EPEX SPOT SE berechnet (Faktor 7), Minimalwert = 12.5 ct/kWh.
Einspeisevergütung:	$c_f = 11 \text{ ct/kWh.}$

2.4.3 Spezifikation der Kennzahlen

2.4.3.1 Reduktion der CO₂-Emissionen

Zur Evaluation der optimierten Steuerung im Hinblick auf die CO₂-Emissionen wird die Energiebilanz des Microgrids betrachtet. Es gilt

$$\sum y_t = \sum b_t + \sum s_t + \sum p_t - \sum f_t - \sum l_t,$$

wobei y_t den Strombedarf, b_t die Stromerzeugung des BHKW, s_t die Solarstromerzeugung, p_t den Netzbezug, f_t die Einspeisung und l_t die Energieverluste durch eine Zwischenspeicherung im Intervall t bezeichnet (s. Abschnitt 2.3.2). Für die Analyse werden die Anteile der verschiedenen Erzeugungseinheiten an der Energieversorgung berechnet:

$$\begin{aligned} A_{\text{BHKW}} &:= \frac{\sum b_t}{\sum y_t}, & A_{\text{PV}} &:= \frac{\sum s_t}{\sum y_t}, \\ A_{\text{Netz}} &:= \frac{\sum p_t}{\sum y_t}, & A_{\text{FIT}} &:= \frac{\sum f_t}{\sum y_t}. \end{aligned} \quad (2.26)$$

Der Anteil der Verluste kann aus diesen Werten rekonstruiert werden. Die Kennzahlen sind unabhängig von den spezifischen Größen im Microgrid wie beispielsweise dem Emissionsfaktor des Strommixes im Netz und dem Gesamtverbrauch im Microgrid $y_{\text{gesamt}} = \sum y_t$. Durch das Einsetzen der spezifischen Werte können die absolute und die relative Reduktion der CO₂-Emissionen für den Stromverbrauch im Microgrid, $r_{\text{CO}_2, \text{abs.}}$ und $r_{\text{CO}_2, \text{rel.}}$, berechnet werden:

$$\begin{aligned} r_{\text{CO}_2, \text{abs.}} &= e_p \sum y_t - (e_b \sum b_t + e_p \sum p_t) \\ &= ((e_p(1 - A_{\text{Netz}}) - e_b A_{\text{BHKW}}) y_{\text{gesamt}} \end{aligned} \quad (2.27)$$

$$\begin{aligned}
 r_{\text{CO}_2, \text{rel.}} &= 1 - \frac{e_b \sum b_t + e_p \sum p_t}{e_p \sum y_t} \\
 &= 1 - A_{\text{Netz}} - \frac{e_b}{e_p} A_{\text{BHKW}}
 \end{aligned} \tag{2.28}$$

2.4.3.2 Reduktion der Betriebskosten

Die beschriebenen Kennzahlen in (2.26) geben auch Aufschluss über die Betriebskosten im Microgrid. Die Stromkosten ohne Microgrid betragen $\sum c_{p,t} y_t$. Diese werden auf $c_g \sum b_t + \sum c_{p,t} p_t$ reduziert. Dazu kommen die Einnahmen durch die Einspeisung von lokal erzeugtem Strom. Liegt ein fester Stromtarif vor, so werden die absolute und relative Reduktion wie folgt berechnet:

$$r_{\text{costs, abs.}} = ((c_p(1 - A_{\text{Netz}}) - c_b A_{\text{BHKW}} + c_f A_{\text{FIT}}) y_{\text{gesamt}}), \tag{2.29}$$

$$r_{\text{costs, rel.}} = 1 - A_{\text{Netz}} - \frac{c_b}{c_p} A_{\text{BHKW}} + \frac{c_f}{c_p} A_{\text{FIT}}. \tag{2.30}$$

Um die Stromkosten für die Hoch- und Niederlasttarife berechnen zu können, wird die Kennzahl A_{Netz} aufgeteilt in jeweilige Anteile zu Hoch- und Niederlastzeiten:

$$A_{\text{HT}} := \frac{\sum_{t \in \{\text{HT-Intervall}\}} p_t}{\sum y_t}, \quad A_{\text{NT}} := \frac{\sum_{t \in \{\text{NT-Intervall}\}} p_t}{\sum y_t}.$$

Im Falle von RTP wird zusätzlich der durchschnittliche Strompreis für den Strom, der aus dem Verteilernetz bezogen wird, angegeben:

$$c_p^\phi := \frac{\sum c_{p,t} p_t}{\sum p_t}.$$

Mit diesen zusätzlichen Parametern kann die Reduktion der Stromkosten für Hoch- und Niederlasttarife sowie RTP analog zu (2.29) und (2.30) berechnet werden.

2.4.3.3 Auslastung des BHKW

Der Anteil des BHKWs an der Energieerzeugung kann erhöht werden, wenn es so groß gewählt wird, dass der Bedarf jederzeit durch das BHKW gedeckt werden kann und so Verluste durch eine Zwischenspeicherung vermieden werden. Dies impliziert jedoch hohe Investitionskosten und eine geringe Auslastung des BHKW. Um dies gegebenenfalls zu erfassen, wird der durchschnittliche Auslastungsgrad ϕ_{AG} des BHKWs aufgezeichnet:

$$\phi_{\text{AG}} := \frac{1}{T} \sum_{t=0}^T \frac{b_t}{b_{\text{max}}},$$

wobei $T = 340 \cdot 96$ den Zeitraum der Simulation beschreibt und entsprechend 340 die Anzahl der simulierten Tage und 96 die Anzahl der Viertelstunden pro Tag beschreiben.

Ein durchschnittlicher Auslastungsgrad von 0,23 entspricht 2000 Volllaststunden im Jahr. Dies ist nach [18] die minimale jährliche Betriebsdauer, mit der ein Mikro-

BHKW wirtschaftlich ist. Ein ϕ_{AG} von 0.46 entspricht 4000 Volllaststunden im Jahr, ein ϕ_{AG} von 0,68 entspricht 6000 Stunden – diese Werte sind nach [49], bzw. [50] empfehlenswert für den Betrieb eines Mikro-BHKW.

2.4.3.4 Glättung des Strombezugs

Es werden üblicherweise zwei Kennzahlen verwendet, um die Vermeidung von Spitzenlasten und die Glättung des Strombezugs zu messen: (1) die prozentuale Reduktion der Spitzenlasten (Peak Reduction, abgekürzt mit PR) durch den Betrieb des Micogrids und (2) das Verhältnis der verbleibenden Spitzenlasten zum durchschnittlich verbleibenden Strombezug (Peak-to-Average Ratio, abgekürzt mit PAR):

$$PR := 1 - \frac{\max_{t \in [0;T]} p_t}{\max_{t \in [0;T]} y_t}, \quad PAR := \frac{\max_{t \in [0;T]} p_t}{\frac{1}{T} \sum_{t=0}^T p_t},$$

wobei $[0; T]$ den Auswertungszeitraum darstellt. Dabei sind insbesondere die Effekte innerhalb eines Tages interessant. Deshalb werden die Kennzahlen täglich berechnet und die Durchschnittswerte davon ermittelt:

$$PR_d := 1 - \frac{1}{K} \sum_{k=0}^{K-1} \frac{\max_{t \in [96k+1; 96(k+1)]} p_t}{\max_{t \in [96k+1; 96(k+1)]} y_t},$$

$$PAR_d := \frac{1}{K} \sum_{k=0}^{K-1} \frac{\max_{t \in [96k+1; 96(k+1)]} p_t}{\frac{1}{96} \sum_{t=96k+1}^{96(k+1)} p_t},$$

wobei $K = 340$ die Anzahl der simulierten Tage beschreibt.

2.4.4 Aufbau der Robustheitsanalyse

Die im nächsten Abschnitt präsentierten Ergebnisse der Optimierung zeigen das Potential durch eine intelligente Betriebsführung des BHKWs und des Speichers. Um zu prüfen, wie sensitiv die Optimierung auf unpräzise Prognosen reagiert, werden Variationen des Strombedarfs, der Solarstromerzeugung und des Tageswärmebedarfs modelliert. Die Handlungsempfehlungen für die Betriebsmodi (d.h. die Terme (2.20) - (2.24)) werden aus der Optimierung mit den bereits modellierten Parametern bestimmt. Die Betriebsführung wird dann für die variierten Parameter unter Nutzung der abgeleiteten Handlungsempfehlungen gemäß (2.25) bestimmt (vgl. Abschnitt 2.3.6).

2.4.4.1 Variation des Strombedarfs

Kurzfristige Stromlastprognosen für einzelne Haushalte haben in der Regel einen relativ hohen mean average percentage error (MAPE). Eine Analyse der State-of-the-Art-Methoden in [51] (vgl. Kapitel 4.2) zeigt auf, dass die Ergebnisse der bestehenden Verfahren bei der Prognose des Stromverbrauchs eines einzelnen Haushaltes bei einem Prognosehorizont von 24 Stunden einen MAPE von 46% nicht

unterschreiten. Dieser Fehler wird naturgemäß kleiner, je mehr Haushalte in die Prognose eingeschlossen sind. In der Analyse von [52] wird bei der Prognose der aggregierten Stromlast von 30 Haushalten ein MAPE von 13% publiziert.

Die Anzahl der Haushalte in der Simulation liegt mit 16, bzw. 12 Haushalten zwischen diesen Werten und es wird daher eine Standardabweichung von 20% angenommen. Jeden Wert y_t wird mit einer Normalverteilung $\mathcal{N}(\mu; \sigma^2)$ variiert, wobei der Erwartungswert μ als y_t und die Standardabweichung σ als $0,2 y_t$ gewählt wird.

2.4.4.2 Variation der Solarstromerzeugung

Die kurzfristigen Prognosen für Solarstromerträge unterliegen ebenfalls gewissen Fehlerraten. Eine umfangreiche Prüfung von Prognosen für die globale Sonneneinstrahlung wird in [53] präsentiert. Darin erreichen Prognosen mit einem Zeithorizont von 24 Stunden und einer Granularität von einer Stunde einen root mean squared error (RMSE) zwischen 25% und 40% des erwarteten Wertes.

Die Variation der Solarstromerzeugung wird ebenfalls mit einer Normalverteilung simuliert. Die Standardabweichung wird dabei auf 30% des erwarteten Wertes s_t gesetzt.

2.4.4.3 Variation des Wärmebedarfs

Die Standardabweichung des täglichen Warmwasserbedarfs zum durchschnittlichen Warmwasserbedarf eines Haushalts ist gemäß [54] kleiner als 30%. Es wird angenommen, dass der tägliche Warmwasserbedarf für jeden Haushalt normalverteilt ist. Für das gesamte Microgrid wird der Wasserbedarf demgemäß mit $\mathcal{N}(50, 41; 16)$ modelliert. Der darüber hinausgehende Wärmebedarf korreliert stark mit der Außentemperatur, deswegen wird die Abweichung vom prognostizierten Wert mit einer geringeren Standardabweichung von 10% des erwarteten Wertes modelliert.

Ist der Tageswärmebedarf kleiner als der erwartete, wird der Betrieb des BHKWs zu dem Zeitpunkt eingestellt, an dem der Tageswärmebedarf abgedeckt ist. Ist der Tageswärmebedarf größer als erwartet, muss mehr Wärme durch den Brennwertkessel erbracht werden. In diesem Fall ändert sich nichts an der Betriebsführung des BHKW.

2.5 Ergebnisse der Simulation

Die Simulation wurde für beide Modelle in unterschiedlichen Ausstattungen über den Zeitraum von Juni 2014 bis Mai 2015 durchgeführt und ausgewertet.

Zunächst werden die Ergebnisse präsentiert, die unter der Annahme erzielt werden, dass die Prognosen exakt sind und der Betrieb des Mikro-BHKWs und des Stromspeichers gemäß der Lösung des Optimierungsproblems (2.16), bzw. (2.17) reguliert werden. Beispieltage für die optimierte Betriebsführung und die Energiebilanz eines Tages sind in den Abb. 2.5 und 2.6 graphisch dargestellt. Die Ergebnisse der Simulation in Form der Kennzahlen werden in den Tabellen 2.3, 2.4 und 2.5

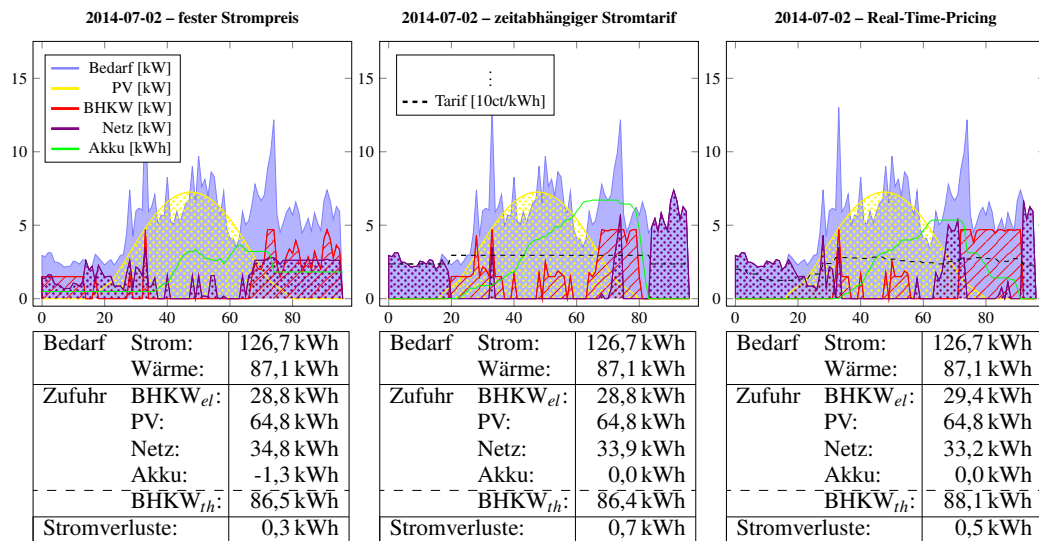


Abbildung 2.5: Optimierte Betriebsführungen für das Microgrid Modell 2 an einem Beispieltage im Juli bei unterschiedlichen Stromtarifen und die zugehörigen Energiebilanzen.

präsentiert. Diese Resultate zeigen das Potential, welches durch die prädiktive Koordination der Einheiten im Microgrid erreicht werden kann und sie werden in den nächsten Abschnitten im Hinblick auf die Energiebilanz, die Reduktion der CO₂-Emissionen und die Betriebskosten analysiert. Anschließend werden die Ergebnisse der Robustheitsanalyse dargestellt und untersucht, wie sich unpräzise Prognosen unter Anwendung der abgeleiteten Handlungsempfehlungen auf die Ergebnisse auswirken.

2.5.1 Energiebilanzen

2.5.1.1 Beispieltage

In den Abb. 2.5 und 2.6 sind die Energiebilanzen des Microgrid Modell 2 für je einen Beispieltage im Juni und Oktober für die unterschiedlichen Stromtarife visualisiert. Die Graphiken illustrieren die Betriebsführung des BHKW und des Speichers. Insbesondere in der Abb. 2.5 sind die Effekte der unterschiedlichen Stromtarife auf die Betriebsführung deutlich erkennbar: Bei den variablen Stromtarife wird das BHKW hauptsächlich zu den Zeiten betrieben, in denen der Strompreis hoch ist; bei dem festen Strompreis ist die Leistung des BHKW besonders hoch, wenn der Bedarf besonders hoch ist. Auf diese Weise wird ein möglichst gleichmäßiger Netzbezug erreicht. Die Menge an lokal erzeugtem Strom umfasst bei allen drei Energietarifen etwa die gleiche Menge. Die maximale Produktionsmenge des BHKWs ist durch den geringen Wärmebedarf beschränkt.

In der Visualisierung der Energiebilanzen für einen Tag im Oktober in Abb. 2.6 fällt auf, dass sich die Betriebsführung des BHKWs nur in geringem Maße bei den




Abbildung 2.6: Optimierte Betriebsführungen für das Microgrid Modell 2 an einem Tag im Oktober bei unterschiedlichen Stromtarifen und die zugehörigen Energiebilanzen.

unterschiedlichen Stromtarife unterscheidet. Dies liegt daran, dass das BHKW aufgrund des hohen Wärmebedarfs immer (unabhängig vom Strompreis) dann betrieben werden kann, wenn der Solarstrom den Bedarf nicht abdeckt. Die Unterschiede zeigen sich erst am Ende des Tages, wenn aufgrund der Spitzenlasten teilweise Strom importiert werden muss. Je nach Energietarif erfolgt der Netzbezug dann besonders gleichmäßig oder zu Zeiten, in denen der Strompreis relativ günstig ist. Dies wird durch die Entladung des Stromspeichers reguliert.

2.5.1.2 Jahresbilanzen

Die Simulation der Microgrids wurde für jedes Modell für 340 Tage durchgeführt. Die Ergebnisse sind in den Tabellen 2.3, 2.4 und 2.5 dargestellt. In ersterer werden die Kennzahlen gezeigt, die für eine Simulation bei einem festen Strompreis und dem untergeordneten Ziel, Spitzenlasten zu vermeiden, erreicht wurden. Die Resultate für die variablen Strompreise sind in den Tabellen 2.4 und 2.5 aufgeschlüsselt. Die fett markierten Zeilen 9 und 20 entsprechen jeweils den Microgrids, die mit Solaranlage, BHKW und Stromspeicher ausgestattet sind und für welche die Optimierungsprobleme (2.17), bzw. (2.16) verwendet wurden. Die Ergebnisse für den alternativen Betriebsmodus sind in Zeilen 4, 5, 10, 11, 15, 16, 21 und 22 dargestellt. Dafür sind die Optimierungsprobleme (2.19), bzw. (2.18) gelöst worden.

Die Anteile der unterschiedlichen Komponenten an der Energieerzeugung A_{BHKW} , A_{PV} , A_{Netz} , A_{FIT} sind die wesentlichen Indikatoren für die Reduktion der CO₂-Emissionen sowie der Betriebskosten (vgl. Abschnitt 2.4.3, Gleichungen (2.27) bis (2.30)). Sie nehmen unter den verschiedenen Energietarifen nahezu dieselben Werte an. Dies liegt daran, dass die Energietarife zwar die Zeiten des BHKW-Betriebs und

Tabelle 2.3: Ergebnisse der Simulation zur optimierten Betriebsführung der Microgrids bei einem festen Strompreis und mit Spitzenlastvermeidung. Die Spalte *Opt.* gibt an, welches Optimierungsproblem in der Simulation gelöst wurde.

	Microgrid Modelle					Kennzahlen						
	Bedarf	PV	BHKW	Akku	Opt.	A_{BHKW}	A_{PV}	A_{Netz}	A_{FIT}	AG	PAR_d	PR_d
1	Modell 1	–	–	–	(2.17)	–	–	1,00	–	–	1,65	–
2	Modell 1	–	4,7 kW	–	(2.17)	0,56	–	0,44	0,00	0,66	2,31	0,46
3	Modell 1	–	4,7 kW	13 kWh	(2.17)	0,61	–	0,39	0,00	0,72	1,60	0,62
4	Modell 1	–	4,7 kW	–	(2.19)	0,62	–	0,44	0,06	0,72	2,31	0,46
5	Modell 1	–	4,7 kW	13 kWh	(2.19)	0,62	–	0,39	0,00	0,72	1,60	0,62
6	Modell 1	18 kWp	–	–	(2.17)	–	0,32	0,70	0,01	–	2,48	0,03
7	Modell 1	18 kWp	–	7 kWh	(2.17)	–	0,32	0,68	0,00	–	2,29	0,12
8	Modell 1	18 kWp	4,7 kW	–	(2.17)	0,50	0,32	0,20	0,02	0,58	3,92	0,56
9	Modell 1	18 kWp	4,7 kW	13 kWh	(2.17)	0,56	0,32	0,13	0,00	0,66	2,90	0,80
10	Modell 1	18 kWp	4,7 kW	–	(2.19)	0,62	0,32	0,20	0,13	0,72	4,12	0,56
11	Modell 1	18 kWp	4,7 kW	13 kWh	(2.19)	0,62	0,32	0,13	0,06	0,73	2,90	0,80
12	Modell 2	–	–	–	(2.17)	–	–	1,00	–	–	2,41	–
13	Modell 2	–	4,7 kW	–	(2.17)	0,56	–	0,44	0,00	0,64	4,58	0,38
14	Modell 2	–	4,7 kW	13 kWh	(2.17)	0,61	–	0,39	0,00	0,70	2,75	0,59
15	Modell 2	–	4,7 kW	–	(2.19)	0,63	–	0,44	0,07	0,72	4,58	0,38
16	Modell 2	–	4,7 kW	21 kWh	(2.19)	0,63	–	0,39	0,02	0,72	2,75	0,60
17	Modell 2	18 kWp	–	–	(2.17)	–	0,32	0,71	0,03	–	3,21	0,10
18	Modell 2	18 kWp	–	7 kWh	(2.17)	–	0,32	0,69	0,01	–	2,78	0,23
19	Modell 2	18 kWp	4,7 kW	–	(2.17)	0,48	0,32	0,23	0,03	0,55	7,02	0,46
20	Modell 2	18 kWp	4,7 kW	13 kWh	(2.17)	0,54	0,32	0,15	0,00	0,63	3,44	0,82
21	Modell 2	18 kWp	4,7 kW	–	(2.19)	0,63	0,32	0,22	0,18	0,72	7,09	0,47
22	Modell 2	18 kWp	4,7 kW	13 kWh	(2.19)	0,63	0,32	0,14	0,09	0,73	3,44	0,82

das Management des Stromspeichers verändern (vgl. Abb. 2.5), die Eigennutzung des Solarstroms und der Betrieb des BHKW zur Deckung des Eigenbedarfs jedoch für jeden Energietarif im Rahmen der Nebenbedingungen maximiert werden.

Der Anteil des Mikro-BHKWs an der Stromversorgung beträgt zwischen 56% und 63% für die Modelle ohne PV-Anlage. Der vom Netz importierte Anteil wird damit auf 39 - 44% gesenkt. Sind PV-Anlagen installiert, so entspricht die Menge des erzeugten Stroms knapp einem Drittel des Strombedarfs. Ist zudem ein Stromspeicher installiert, kann dieser Strom nahezu vollständig zur Eigenversorgung genutzt werden (vgl. Tab. 2.3, 2.4, 2.5, Zeilen 9, 11, 20, 22). **In Kombination mit dem BHKW können damit 85 - 87% des Strombedarfs durch lokal erzeugten Strom abgedeckt werden.**

In Abb. 2.7 sind die monatlichen Anteile A_{BHKW} , A_{PV} und A_{Netz} der verschiedenen Stromlieferanten für die voll ausgestatteten Microgrids abgebildet, um einen Einblick über die Stromversorgung im Laufe des Jahres zu geben. Der Anteil der Solarenergie ist in den Sommermonaten am höchsten. Dabei wird der höchste Wert in beiden Modellen im Monat Juli mit knapp 60% angenommen. Im Winter liegt der Anteil des Solarstroms bei weniger als 10%. Das BHKW deckt jeden Monat mehr als 20% des Strombedarfs ab. Von Oktober bis März steigt der Anteil auf über 60% bis zu knapp 80%. Bei dem Verlauf des Netzbezugs zeigen sich leichte Unterschiede zwischen der Modellierung mit Durchschnittswerten und Standardlastkurven in

Tabelle 2.4: Ergebnisse der Simulation zur optimierten Betriebsführung der Microgrids bei dem zeitabhängigen Stromtarif.

	Microgrid Modelle					Kennzahlen						
	Bedarf	PV	BHKW	Akku	Opt.	A _{BHKW}	A _{PV}	A _{Netz}	A _{FIT}	AG	A _{HT}	A _{HT}
1	Modell 1	–	–	–	(2.16)	–	–	1,00	–	–	0,81	0,19
2	Modell 1	–	4,7 kW	–	(2.16)	0,56	0,00	0,44	0,00	0,65	0,36	0,08
3	Modell 1	–	4,7 kW	13 kWh	(2.16)	0,61	–	0,39	0,00	0,72	0,32	0,08
4	Modell 1	–	4,7 kW	–	(2.18)	0,62	–	0,44	0,06	0,72	0,36	0,08
5	Modell 1	–	4,7 kW	13 kWh	(2.18)	0,62	–	0,39	0,01	0,72	0,32	0,08
6	Modell 1	18 kWp	–	–	(2.16)	–	0,32	0,70	0,01	–	0,51	0,19
7	Modell 1	18 kWp	–	7 kWh	(2.16)	–	0,32	0,68	0,00	–	0,49	0,19
8	Modell 1	18 kWp	4,7 kW	–	(2.16)	0,50	0,32	0,20	0,01	0,58	0,16	0,04
9	Modell 1	18 kWp	4,7 kW	13 kWh	(2.16)	0,56	0,32	0,13	0,00	0,66	0,08	0,04
10	Modell 1	18 kWp	4,7 kW	–	(2.18)	0,62	0,32	0,20	0,14	0,72	0,15	0,05
11	Modell 1	18 kWp	4,7 kW	13 kWh	(2.18)	0,62	0,32	0,13	0,06	0,73	0,08	0,04
12	Modell 2	–	–	–	–	–	–	1,00	–	–	0,80	0,20
13	Modell 2	–	4,7 kW	–	(2.16)	0,56	–	0,44	0,00	0,64	0,37	0,07
14	Modell 2	–	4,7 kW	13 kWh	(2.16)	0,61	–	0,39	0,00	0,70	0,32	0,07
15	Modell 2	–	4,7 kW	–	(2.18)	0,63	–	0,44	0,07	0,72	0,37	0,07
16	Modell 2	–	4,7 kW	13 kWh	(2.18)	0,63	–	0,39	0,02	0,72	0,31	0,07
17	Modell 2	18 kWp	–	–	(2.16)	–	0,32	0,71	0,03	–	0,51	0,20
18	Modell 2	18 kWp	–	7 kWh	(2.16)	–	0,32	0,69	0,01	–	0,49	0,20
19	Modell 2	18 kWp	4,7 kW	–	(2.16)	0,48	0,32	0,23	0,03	0,55	0,18	0,05
20	Modell 2	18 kWp	4,7 kW	13 kWh	(2.16)	0,54	0,32	0,15	0,00	0,63	0,09	0,05
21	Modell 2	18 kWp	4,7 kW	–	(2.18)	0,63	0,32	0,23	0,18	0,72	0,17	0,06
22	Modell 2	18 kWp	4,7 kW	13 kWh	(2.18)	0,63	0,32	0,15	0,09	0,73	0,09	0,05

Tabelle 2.5: Ergebnisse der Simulation zur optimierten Betriebsführung der Microgrids bei Real-Time-Pricing.

	Microgrid Modelle					Kennzahlen					
	Bedarf	PV	BHKW	Akku	Opt.	A _{BHKW}	A _{PV}	A _{Netz}	A _{FIT}	AG	c _p ^o
1	Modell 1	–	–	–	–	–	–	1,00	–	–	28,46
2	Modell 1	–	4,7 kW	–	(2.16)	0,56	0,00	0,44	0,00	0,66	26,40
3	Modell 1	–	4,7 kW	13 kWh	(2.16)	0,61	–	0,39	0,00	0,72	24,95
4	Modell 1	–	4,7 kW	–	(2.18)	0,62	–	0,44	0,06	0,72	26,40
5	Modell 1	–	4,7 kW	13 kWh	(2.18)	0,62	–	0,39	0,00	0,72	24,95
6	Modell 1	18 kWp	–	–	(2.16)	–	0,32	0,70	0,01	–	29,20
7	Modell 1	18 kWp	–	7 kWh	(2.16)	–	0,32	0,68	0,00	–	29,25
8	Modell 1	18 kWp	4,7 kW	–	(2.16)	0,50	0,32	0,20	0,01	0,58	29,02
9	Modell 1	18 kWp	4,7 kW	13 kWh	(2.16)	0,56	0,32	0,13	0,00	0,66	25,31
10	Modell 1	18 kWp	4,7 kW	–	(2.18)	0,62	0,32	0,20	0,13	0,72	28,99
11	Modell 1	18 kWp	4,7 kW	13 kWh	(2.18)	0,62	0,32	0,13	0,06	0,73	25,30
12	Modell 2	–	–	–	–	–	–	1,00	–	–	28,10
13	Modell 2	–	4,7 kW	–	(2.16)	0,56	–	0,44	0,00	0,64	25,89
14	Modell 2	–	4,7 kW	13 kWh	(2.16)	0,61	–	0,39	0,00	0,70	24,56
15	Modell 2	–	4,7 kW	–	(2.18)	0,63	–	0,44	0,07	0,72	25,89
16	Modell 2	–	4,7 kW	13 kWh	(2.18)	0,63	–	0,39	0,02	0,72	24,56
17	Modell 2	18 kWp	–	–	(2.16)	–	0,32	0,71	0,03	–	28,67
18	Modell 2	18 kWp	–	7 kWh	(2.16)	–	0,32	0,69	0,01	–	28,64
19	Modell 2	18 kWp	4,7 kW	–	(2.16)	0,48	0,32	0,23	0,03	0,55	28,07
20	Modell 2	18 kWp	4,7 kW	13 kWh	(2.16)	0,54	0,32	0,14	0,00	0,63	24,63
21	Modell 2	18 kWp	4,7 kW	–	(2.18)	0,63	0,32	0,22	0,18	0,73	27,97
22	Modell 2	18 kWp	4,7 kW	13 kWh	(2.18)	0,63	0,32	0,15	0,09	0,73	24,62




Abbildung 2.7: Monatliche Anteile der unterschiedlichen Komponenten an der Stromversorgung

Modell 1 und den empirischen Daten in Modell 2: Von Juni bis September muss im Modell 2 mehr Strom importiert werden als in Modell 1. Dies liegt daran, dass das Verhältnis von Strom zu Wärmebedarf in den empirischen Daten ungünstiger ausfällt als bei den Durchschnittswerten in Modell 1. Für beide Modelle liegt der monatliche Anteil des Netzbezugs über das ganze Jahr hinweg bei weniger als 26%.

Der Auslastungsgrad des BHKWs variiert im Laufe des Jahres ähnlich wie A_{BHKW} . Für jedes Modell wird eine Auslastung über 80% in den Monaten von November bis Februar erreicht. Insgesamt liegt der Auslastungsgrad je nach Ausstattung des Microgrids zwischen 55% und 73%. Somit wird in allen Modellen der Schwellenwert von 48% aus [49] erreicht, was ein Hinweis darauf ist, dass die Leistung des BHKWs in einer geeigneten Größe gewählt wurde. Dabei ist zu erwähnen, dass der Auslastungsgrad jeweils am niedrigsten ist, wenn eine Solaranlage, aber kein Stromspeicher installiert ist. Wird die alternative Zielsetzung verfolgt und das Optimierungsproblem (2.18), bzw. (2.19) gelöst, steigen die Auslastungsgrade des BHKW auf 72 - 73%. Höhere Auslastungsgrade sind auf den betrachteten Datensätzen aufgrund der Bedingung (2.10), welche sicherstellt, dass keine überschüssige Wärme produziert wird, nicht erreichbar.

2.5.2 Ökobilanzen

Je weniger Strom aus dem Verteilernetz gezogen werden muss, desto niedriger sind die CO_2 -Emissionen und die Betriebskosten. Die niedrigsten Stromimporte sind für Microgrids mit PV-Anlagen, BHKW und Stromspeicher nötig. In dieser Konstellation müssen nur noch 13-15% des Strombedarfs importiert werden. Unter der Nutzung der Emissionsfaktoren aus Abschnitt 2.3.3 ($e_b = 224 \text{ g/kWh}$, $e_p = 587 \text{ g/kWh}$) ku-

Tabelle 2.6: CO₂-Emissionen für verschiedene Szenarien der Energieversorgung im modellierten Microgrid (Modell 2): bei einer optimierten lokalen Energieerzeugung mit einem Mikro-BHKW und PV-Anlagen, bei der Energieerzeugung mit jeweils einer der Komponenten und bei einer konventionellen Stromversorgung

Modell 2				
Stromerzeugende Komponenten	BHKW PV	BHKW –	– PV	konventionelle Stromversorgung
BHKW (Strom)	5,40 t	6,05 t		
Netzbezug	3,76 t	10,22 t	17,88 t	25,92 t
Σ Strom	9,16 t	14,06 t	17,88 t	25,92 t
BHKW (Wärme)	16,20 t	18,15 t	–	–
Gasheizung	7,09 t	5,14 t	23,29 t	23,29 t
Σ Wärme	23,29 t	23,29 t	23,29 t	23,29 t
CO₂-Emissionen pro Jahr	32,45 t	39,56 t	41,17 t	49 20 t
Reduktion pro Jahr				
absolut	16,75 t	9,64 t	8,03 t	–
relativ	34%	20%	16%	–

mulieren sich die CO₂-Emissionen für die Stromversorgung im Modell 2 auf $e_{electr.} = 9,16$ t. Vergleicht man dies mit den CO₂-Emissionen von 25,92 t, die anfallen, wenn der Strom ausschließlich aus dem Verteilernetz bezogen wird, so wird eine Reduktion von $e_{electr.}$ um 65% erreicht. (Die Werte werden mithilfe der Gleichungen (2.27) und (2.28) berechnet.) Betrachtet man die CO₂-Emissionen der gesamten Energieversorgung inklusive der Wärmeversorgung, so beträgt $e_{total} = 32,45$ t im Vergleich zu 49,20 t bei einer konventionellen Strom- und Wärmeversorgung. **Dies entspricht einer Reduktion der gesamten CO₂-Emissionen um 34%.**

Dieses Ergebnis wird für das komplett ausgestattete Microgrid im Modell 2 erreicht. In Tab. 2.6 sind die CO₂-Emissionen für vier unterschiedliche Ausstattungen des Microgrids im Modell 2 dargestellt. Es wird das Microgrid mit (1) kompletter Ausstattung, (2) ohne PV-Anlage, (3) ohne Mikro-BHKW und (4) ohne stromerzeugende Komponenten betrachtet. Dies entspricht den Konstellationen, welche in den Zeilen 12, 14, 17 und 20 in Tab. 2.3 beschrieben werden. Sind keine PV-Anlagen integriert, werden durch die optimierte Betriebsführung des Mikro-BHKWs 20% der CO₂-Emissionen vermieden. Sind im Vergleich dazu PV-Anlagen von 18 kWp vorhanden, aber kein BHKW, so beträgt die Reduktion der CO₂-Emissionen 16%. Diese Werte unterstreichen einen wesentlichen Effekt der Optimierung: Die unabhängig voneinander erreichten Einsparungen der PV-Anlage und des BHKWs können unter der koordinierten Betriebsführung nahezu aufsummiert werden. Die Reduktion bei gemeinsamer Nutzung beträgt 34%. Dies zeigt, wie gut sich die beiden Technologien ergänzen, wenn sie aufeinander abgestimmt betrieben werden. Würde stattdessen nur eine der Einheiten in der doppelten Größe gewählt, wäre der Effekt deutlich

kleiner, da das BHKW durch die gekoppelte Wärmeversorgung nur begrenzt betrieben werden kann und die Nutzung der PV-Anlage zur Eigenversorgung durch die Volatilität in der Erzeugung ebenfalls begrenzt wird.

Die gesamten CO₂-Emissionen können sogar weiter reduziert werden, wenn anstelle von Erdgas Biogas für den Betrieb des BHKWs verwendet wird. In diesem Fall würden sich die CO₂-Emissionen nochmals reduzieren und nur noch 22% im Vergleich zu einer konventionellen Energieversorgung betragen. Wird zudem auch die Gasheizung mit Biogas betrieben, werden nur noch 7% der CO₂-Emissionen freigesetzt, welche der Wohnblock ohne Microgrid-Komponenten und mit Erdgas als Brennstoff freisetzen würde. Allerdings steigen auch die Betriebskosten deutlich. Für einen aktuell verfügbaren Biogaspreis von 9,9 ct/kWh¹¹ ist $c_b = 11$ ct/kWh. Dadurch erhöhen sich die jährlichen Betriebskosten um rund 4.400 €.

2.5.3 Analyse der Betriebskosten

Die Ersparnisse in den Betriebskosten der Stromversorgung hängen von dem verwendeten Stromtarif (vgl. Tabelle 2.2) ab. Für den festen Strompreis betragen die Stromkosten im Modell 2 für das komplett ausgestattete Microgrid 3.691 Euro. Wird der Strom ausschließlich aus dem Verteilernetz bezogen, betragen die Stromkosten 13.029 Euro. Die Stromkosten verringern sich damit um 9.338 Euro, bzw. um 72%. Für den zeitabhängigen Stromtarif werden die Kosten von 12.510 auf 3.544 Euro verringert, für variable Strompreise werden die Kosten von 12.407 auf 3.394 Euro gesenkt. Für jeden Stromtarif sinken die Betriebskosten für die Stromversorgung durch den optimierten Betrieb des Microgrids um mindestens 8.950 Euro und damit um ca. 72% gegenüber einer konventionellen Stromversorgung. **Umgerechnet auf die gesamte Energieversorgung inklusive der Wärmeversorgung werden zwischen 44% und 45% der Betriebskosten gespart.**

Eine Übersicht der Betriebskosten für das Microgrid (Modell 2) in unterschiedlicher Ausstattung unter der Annahme des festen Energietarifs ist in Tabelle 2.7 gegeben. Neben den vier Konstellationen, welche bereits hinsichtlich der CO₂-Emissionen untersucht wurden, werden auch die Betriebskosten des alternativen Betriebsmodus bei kompletter Ausstattung des Microgrids dargestellt. Wie in Abschnitt 2.3.4 ausgeführt, sind weitere steuerliche Vorteile möglich, die in dieser Analyse nicht berücksichtigt sind. Der größte Effekt auf der Reduktion der Betriebskosten wird durch den gemeinsamen Betrieb des BHKWs und der Solaranlage erzielt. Bemerkenswert ist, dass die Betriebskosten bei alleiniger Nutzung eines Mikro-BHKWs geringer sind als bei der alleinigen Nutzung einer PV-Anlage. Durch den alternativen Betriebsmodus, bei welchem zusätzliche CO₂-Emissionen in Kauf genommen werden, welche durch die Bereitstellung von Strom verursacht werden, der in das Verteilernetz eingespeist wird, verringern sich die Betriebskosten nur geringfügig.

¹¹ <https://www.naturstrom.de/privatkunden/gas/>, letzter Zugriff am 26.09.2016

Tabelle 2.7: Betriebskosten für verschiedene Szenarien der Energieversorgung im modellierten Microgrid (Modell 2): bei einer optimierten lokalen Energieerzeugung mit einem Mikro-BHKW und PV-Anlagen, bei der Energieerzeugung mit jeweils einer der Komponenten und bei einer konventionellen Stromversorgung

Modell 2					
Stromerzeugende Komponenten	BHKW PV	BHKW –	– PV	altern. Betrieb	konvent. Energiev.
BHKW (Strom)	1.820 €	2.040 €	–	2.118 €	–
Netzbezug	1.892 €	5.140 €	8.990 €	1888 €	13.029 €
Einspeisung	-21 €	0 €	-46 €	-452 €	–
∑ Strom	3.691 €	7.180 €	8.944 €	3553 €	13.029 €
BHKW (Wärme)	5.460 €	6.119 €	–	6.353 €	–
Gasheizung	2.391 €	1.732 €	7.851 €	1.498 €	7.851 €
∑ Wärme	7.851 €	7.851 €	7.851 €	7.851 €	7.851 €
Betriebskosten pro Jahr	11.542 €	15.031 €	16.795 €	11.404 €	20.880 €
Reduktion pro Jahr					
absolut	9.338 €	5.849 €	4.085 €	9.475 €	–
relativ	45%	28%	20%	45%	–

2.5.4 Reduktion der Spitzenlasten

Die Spitzenlasten im Stromverbrauch werden durch den Betrieb des Microgrids erheblich gesenkt (vgl. Tab. 2.3). Dies ist nicht verwunderlich, da insgesamt der Netzbezug verringert wird. Dabei ist jedoch bemerkenswert, welche Rolle die Komponenten des Microgrids in der Reduktion spielen: Sind ausschließlich PV-Anlagen installiert, so werden die Spitzenlasten nur um 3% im Modell 1 und um 10% im Modell 2 gesenkt (vgl. Tab. 2.3, Zeilen 6, 17). Durch die zusätzliche Installation eines Stromspeicher wird die PR auf 12%, bzw. 23% erhöht (vgl. Tab. 2.3, Zeilen 7,18). Der Effekt des Mikro-BHKWs auf die Reduktion der Spitzenlasten ist unter der optimierten Betriebsführung wesentlich höher: Bereits ohne Stromspeicher können die Spitzenlasten um 46%, bzw. 38% reduziert werden, mit Speicher um 62%, bzw. 59%. Wird das BHKW gemeinsam mit PV-Anlagen und einem Stromspeicher betrieben, so kann die Reduktion nochmals wesentlich erhöht werden. **Durch die koordinative Betriebsführung sind die Spitzenlasten um 80%, bzw. 82% geringer als bei einer konventionellen Stromversorgung.**

Das Verhältnis der Spitzenlasten zum durchschnittlichen Stromimport, sprich die PAR, erhöht sich durch die Installation der stromerzeugenden Komponenten. Dieser Effekt tritt insbesondere dann auf, wenn PV-Anlagen ohne Stromspeicher installiert werden: Der Netzbezug wird zwar gesenkt, doch der Eigenverbrauch der Solarenergie erfolgt nur begrenzt in den Zeiten, in denen Spitzenlasten auftreten. Dadurch wird die PAR größer. Dieser Effekt verstärkt sich sogar, wenn das BHKW

Fester Tarif	Kennzahlen					
Variation	A_{BHKW}	A_{PV}	A_{Netz}	A_{FIT}	PAR_d	PR_d
–	54,3	32,3	14,6	0,4	3,42	0,82
Strombedarf	53,4	32,3	15,9	0,7	5,74	0,70
Solarstrom	53,7	32,3	15,6	0,6	3,70	0,80
Wärmebedarf	53,4	32,3	15,5	0,3	3,55	0,80
Gemeinsam	53,3	32,3	16,2	0,8	5,88	0,68

2 stuf. Tarif	Kennzahlen					
Variation	A_{BHKW}	A_{PV}	A_{Netz}	A_{FIT}	A_{HT}	A_{NT}
–	54,4	32,3	14,6	0,3	9,1	5,5
Strombedarf	54,1	32,3	14,9	0,3	9,4	5,5
Solarstrom	54,6	32,3	14,6	0,4	9,2	5,4
Wärmebedarf	54,1	32,3	14,9	0,3	9,2	5,7
Gemeinsam	53,8	32,3	15,5	0,4	9,9	5,7

RTP	Kennzahlen					
Variation	A_{BHKW}	A_{PV}	A_{Netz}	A_{FIT}	c_p^0	
–	54,5	32,3	14,5	0,3	24,63	
Strombedarf	53,8	32,3	15,2	0,3	25,09	
Solarstrom	54,4	32,3	14,7	0,4	24,91	
Wärmebedarf	54,1	32,3	14,8	0,3	24,66	
Gemeinsam	53,5	32,3	15,7	0,4	25,12	

Abbildung 2.8: Ergebnisse der Robustheitsanalyse: Die Tabelle oben links zeigt die Kennzahlen für die Simulation unter Verwendung der variierten Eingabedaten für den Strombedarf, die Solarstromerzeugung, den Wärmebedarf und der Kombination derselben bei einem festen Stromtarif. Die Tabelle unten links zeigt die Resultate bei dem zeitabhängigen Tarif und die Tabelle oben rechts für RTP.

und die PV-Anlagen gemeinsam ohne Stromspeicher betrieben werden. Dies liegt dann insbesondere daran, dass weniger als 25% des Stroms aus dem Netz gezogen werden und die verbleibenden Peaks so einen großen Einfluss auf die PAR haben. Durch einen Stromspeicher wird dieser Effekt abgeschwächt. Dennoch bleibt das Verhältnis der Spitzenlasten zum durchschnittlichen Stromimport erhöht.

2.5.5 Robustheitsanalyse

Die Robustheitsanalyse, beschrieben in Abschnitt 2.4.4, wird für das voll ausgestattete Microgrid des Modells 2 durchgeführt. Die Ergebnisse sind in der Abb. 2.8 dargestellt. Dabei sind die Kennzahlen der Anteile an der Stromversorgung A_{BHKW} , A_{PV} , A_{Netz} und A_{FIT} in Prozentzahlen angegeben, um die Effekte der ungenauen Prognosen zu verdeutlichen und sie vergleichen zu können.

Die Ausführung des abgeleiteten Betriebsmodus (vgl. Abschnitt 2.3.6) führt bei den variierten Eingabedaten zu einem geringen Verlust des Selbstversorgungsgrades: Wenn alle Eingabewerte variiert werden, verliert A_{BHKW} einen Prozentpunkt, während der Anteil des Netzbezuges A_{Netz} um 1 – 1,6 Prozentpunkte ansteigt. Darüber hinaus verändern sich die Zeiten des Stromimports: Für den zeitabhängigen Stromtarif muss mehr Strom (0,8%) zu den Hochlastzeiten importiert werden und für RTP steigt der durchschnittliche Strompreis für den importierten Strom um einen halben Cent. Der größte Unterschied tritt bei der Vermeidung der Spitzenlasten auf. Durch die ungenauen Prognosen kann der Netzbezug nicht mehr optimal geglättet werden. Es wird dennoch eine PR von 68% erreicht.

Insgesamt sind die Effekte der ungenauen Prognosen auf die Ergebnisse der Betriebsführung sehr gering. Das liegt daran, dass die Kontrollvariablen prädiktiv aus der optimalen Lösung des Optimierungsproblems für einen kompletten Tag

bestimmt werden, aber die tatsächliche Ausführung auch von den aktuellen Daten im Microgrid abhängt.

Die robusten Ergebnisse für die Kennzahlen spiegeln sich entsprechend in der Reduktion der CO₂-Emissionen und der Betriebskosten wieder. Im Vergleich zu einer konventionellen Energieversorgung werden **immer noch 33% der CO₂-Emissionen vermieden und die Betriebskosten weiterhin um 44% gesenkt.**

2.6 Diskussion

Die Ergebnisse des entwickelten Betriebsmodus für ein Mikro-BHKW zur optimalen Nutzung lokaler Ressourcen sind vielversprechend. Die durchgeführten Simulationen zeigen, dass ein hoher Anteil der CO₂-Emissionen durch den vorgestellten Ansatz eingespart und gleichzeitig die Betriebskosten der Energieversorgung verringert werden können. Da in der Simulation gewisse Vereinfachungen getroffen wurden, werden diese im Folgenden diskutiert und weitergehende Forschungsfragen dargestellt.

2.6.1 Einschränkende Faktoren

Während der Strombedarf sowohl anhand von Durchschnittswerten als auch auf Basis individueller Verbrauchsdaten simuliert wurde, wurde der tägliche Wärmebedarf ausschließlich durch einen monatspezifischen Durchschnittswert modelliert. In der Simulation wurde die Produktion des Mikro-BHKW dadurch beschränkt, dass die Erzeugung von Wärme nicht den täglichen Wärmebedarf überschreitet. Dabei wurde angenommen, dass der Wärmespeicher groß genug ist, um den Wärmebedarf entsprechend zu puffern. Zur Validierung dieser Annahme müssten in die Simulation Zeitreihen für den Wärmebedarf integriert werden. Zum Zeitpunkt der Analyse konnten weder Standardlastkurven noch individuelle Messwerte zu dem Wärmebedarf von Haushalten gefunden werden.

Weiterhin wurden die Stromverluste durch die Zwischenspeicherung dargestellt, während die Wärmeverluste durch eine Speicherung vernachlässigt wurden. Um diese korrekt in der Simulation darzustellen, muss der Wärmespeicher detaillierter modelliert werden, da die Verluste von der jeweils aktuellen Temperatur des Speichers abhängen. Auf den Betriebsmodus wirkt sich diese zusätzliche Modellierung allerdings nur geringfügig aus, da der Brennwertkessel den zusätzlichen Wärmebedarf, der nicht über das BHKW erbracht wird, abdeckt. An den Ergebnissen würde sich nur insofern etwas ändern, dass sich die Wärmeproduktion des Brennwertkessels leicht erhöht. Im Vergleich zu einer konventionellen Wärmeversorgung sollten nur geringfügig erhöhte Wärmeverluste anfallen.

Die betriebswirtschaftliche Analyse beschränkte sich auf die Reduktion der laufenden Betriebskosten. Im Fokus steht die optimierte Betriebsführung des BHKWs und es wurde gezeigt, dass durch sie 44% der Betriebskosten im Vergleich zu einer konventionellen Strom- und Wärmeversorgung eingespart werden können. Für eine gesamtwirtschaftliche Analyse eines Microgrids müssen diese mit den Investitionskosten für den Aufbau des Microgrids verrechnet werden.

Die technische Umsetzung und der Aufbau der Kommunikationsinfrastruktur wurden in der Studie nicht betrachtet. Entsprechende Kommunikationsschnittstellen liegen für die Komponenten größtenteils vor. Dennoch muss darüber hinaus ein entsprechendes Datenbanksystem aufgesetzt werden. Ein geeignetes Gateway zur Erfassung der Smart Metering- und Messdaten und Implementierung von Energiemanagementfunktionen ist beispielsweise das Open Gateway Energy Management (OGEMA), welches von den Fraunhofer Instituten IWES, Fraunhofer IIS und Fraunhofer ISE entwickelt (vgl. [55]) wurde. Dieses Gateway oder eine ähnliche Plattform müsste für die tatsächliche Umsetzung des vorgestellten Betriebsmodus installiert werden. Die Investitionskosten hierfür müssten in einer weitergehenden betriebswirtschaftlichen Analyse ebenfalls berücksichtigt werden.

2.6.2 Weitergehende Forschungsfragen

Weitergehende Forschungsfragen ergeben sich zum Teil direkt aus den einschränkenden Faktoren. So ist eine Validierung der Simulationsergebnisse mit empirischen Wärmedaten und der Berücksichtigung der Wärmeverluste durch den Wärmespeicher von Interesse für die Weiterentwicklung des Operationsmodus.

Weiterhin sollte untersucht werden, wie schnell sich die Investitionskosten des Microgrids amortisieren. Dabei wäre eine Analyse zur optimalen Dimensionierung der Einheiten von besonderem Interesse. In der vorliegenden Arbeit wurden die positiven Effekte eines Stromspeichers deutlich: Er trägt wesentlich dazu bei, den Selbstversorgungsgrad zu steigern, wodurch CO₂-Emissionen und Betriebskosten gespart werden können, zudem wird der Stromimport in günstigere Zeiten gelegt. Nichtsdestoweniger sind die Investitionskosten für Stromspeicher zur Zeit noch sehr hoch und eine Untersuchung zur optimalen Skalierung im Hinblick auf die Amortisationszeit ist für den wirtschaftlichen Betrieb von Microgrids von großer Bedeutung.

Die optimale Wahl der Kapazitäten hängt dabei u. a. von dem Verhältnis des Bedarfs von Strom und Wärme ab. In der vorliegenden Arbeit wurde die optimierte Betriebsführung für ein Microgrid in Deutschland untersucht und die Größenordnung der Komponenten entsprechend gewählt. Für andere Länder müssen die Kapazitäten gemäß der jeweiligen dortigen Verhältnissen angepasst werden. So wäre zum Beispiel für einen südeuropäisches Land eine größere Solaranlage und ein kleineres BHKW angemessen. Die koordinierte Betriebsführung selbst kann genauso implementiert werden wie in der vorliegenden Arbeit, da nur die entsprechenden Werte für die Variablen im Optimierungsproblem eingesetzt werden müssen.

Der entwickelte Algorithmus verhält sich sehr robust gegenüber kleinen Fehlern in den Prognosen. Dennoch besteht ein mögliches Optimierungspotenzial darin, den Algorithmus im Laufe eines Tages rollierend neu zu berechnen und so Updates der Prognosen in der Betriebsführung zu berücksichtigen.

Für die Umsetzung der entwickelten Betriebsführung bedarf es einer Einbettung in eine geeignete Softwareplattform mit Schnittstellen zu den einzelnen Komponenten des Microgrids. Die Bereitstellung und die Vereinheitlichung von Kommunikationsschnittstellen stellt weiteren Forschungsbedarf im Kontext von Microgrids

dar. Dabei müssen der Schutz der personenbezogenen Daten sowie der Schutz vor Angriffen von außen zuverlässig gewährleistet werden.

2.7 Zusammenfassung

Es wurde ein optimierter Betriebsmodus für ein Mikro-BHKW in Kombination mit Stromspeichern und PV-Anlagen im Microgrid entwickelt. Für die Evaluation wurden zwei Microgrids mit jeweils unterschiedlichen Ausstattungen simuliert. Dabei wurde der Strombedarf einmal auf Basis von Standardlastkurven und einmal auf Basis realer Verbrauchsdaten einzelner Haushalte simuliert. Der Wärmebedarf und die Solarstromerzeugung wurden mit monatlichen Durchschnittswerten für einen Standort in Deutschland modelliert. Die Größenwahl der Komponenten basierte auf dem angenommenen Strom- und Wärmebedarf.

Für die simulierten Microgrids wurde durch die koordinierte Betriebsführung ein Selbstversorgungsgrad von bis zu 85% in der Stromversorgung erreicht. Dabei ergänzten sich die Stromerzeugung des BHKWs und der PV-Anlagen über den Jahresverlauf gut; der Eigenanteil der Stromversorgung betrug in jedem Monat mehr als 74%. Der Ansatz führte zu einer deutlichen Reduktion der CO₂-Emissionen. Im Vergleich zu einer konventionellen Stromversorgung wurden sie um ca. 65% gesenkt. Bezogen auf die gesamte Energieversorgung wurden 33% der CO₂-Emissionen vermieden, bei der Nutzung von Biogas zum Betrieb des Mikro-BHKWs und des Brennwertkessels sogar bis zu 78%. Weiterhin wurden die laufenden Betriebskosten um 44% im Vergleich zu einer konventionellen Stromversorgung gesenkt. Ferner wurde der verbleibende Netzbezug optimiert. Bei einem festen Strompreis wurde angestrebt, Peaks im Netzbezug zu vermeiden. Diese wurden in der Simulation um 68% reduziert. Bei zeitvariablen Stromtarifen erfolgte der verbleibende Netzbezug hauptsächlich zu Zeiten, in welchen diese niedrig waren. Da sie an die Preise an der Strombörse gekoppelt waren, würde somit zu einem Ausgleich von Angebot und Nachfrage beigetragen.

Die erreichten Ergebnisse sind zwar unter gewissen Limitierungen (vgl. Abschnitt 2.6.1) zu betrachten, dennoch offenbart die Analyse das Potential, welches in der lokalen Optimierung der Energieversorgung liegt. Zu den positiven Effekten der Optimierung tragen insbesondere drei konzeptionelle Maßnahmen bei:

- die gemeinsame Betrachtung der Strom- und Wärmeversorgung,
- die Nutzung von KWK in Kombination mit PV-Anlagen,
- die koordinierte, prädiktive Steuerung der Komponenten.

Die gemeinsame Nutzung und die koordinierte Steuerung der KWK- und PV-Anlage steigern die Gesamtwirtschaftlichkeit durch eine höhere Rentabilität der Anlagen. Aufgrund des Zusammenschlusses wird zum einen der Eigenverbrauch des Solarstroms erhöht und zum anderen ein erhöhter Auslastungsgrad des BHKWs bei ausschließlich lokaler Nutzung des erzeugten BHKW-Stroms erreicht.

Zusammengefasst zeigt die vorliegende Studie einen dezentralen Ansatz zur Energieversorgung von Wohnblöcken und mit dem hierfür entwickelte Algorithmus zur Betriebsführung eines Mikro-BHKWs wurden in der Simulation wesentliche Vorteile gegenüber einer konventionellen Energieversorgung erreicht:

- Der Eigenanteil an der Stromversorgung betrug 85%.
- Die CO₂-Emissionen der Energieversorgung wurden somit um 33% gesenkt.
- Die Betriebskosten der Energieversorgung wurden um 44% gesenkt.
- Der verbleibende Netzbezug wurde so optimiert, dass entweder direkt oder indirekt ein Beitrag zur Netzstabilität geleistet wird.

Die Ergebnisse erwiesen sich dabei robust gegenüber ungenauen Prognosen.

Optimierung des Stromverbrauchs durch Demand Side Management

Contents

3.1	Ansatz	50
3.2	Grundlagen und verwandte Arbeiten	51
3.2.1	DSM-Verfahren einzelner Haushalte	52
3.2.2	Koordinative DSM-Verfahren	53
3.2.3	Förderung von DSM in Deutschland	56
3.2.4	Gewählte Ansätze für die Modellierung	57
3.3	Modellierung	58
3.3.1	Modellierung der Komponenten	58
3.3.2	Modellierung der Stromtarife	60
3.3.3	Modellierung der CO ₂ -Emissionen	60
3.3.4	Optimierungsziele	61
3.3.5	Umsetzung der DSM-Verfahren	62
3.3.6	Konvergenzverhalten gegen globales Optimum	64
3.4	Simulation	66
3.4.1	Spezifikation der Komponenten	66
3.4.2	Spezifikation der Stromtarife	67
3.4.3	Spezifikation der CO ₂ -Emissionsfaktoren	68
3.4.4	Kennzahlen	68
3.5	Ergebnisse der Simulation	69
3.5.1	Energiebilanzen	69
3.5.2	Glättung des Strombezugs	71
3.5.3	Reduktion der Stromkosten	73
3.5.4	Reduktion der CO ₂ -Emissionen	74
3.6	Diskussion	76
3.6.1	Zielsetzung von DSM	76
3.6.2	Konzeption der Stromtarife	77
3.6.3	Unsicherheiten in der Optimierung	78
3.6.4	Kommunikationsinfrastruktur und Datensicherheit	78
3.6.5	Flexibilität und weiteres Potenzial	79
3.7	Zusammenfassung	79

3.1 Ansatz

Demand Side Management bezeichnet Methoden zur Modifikation des Strombedarfs mit dem Ziel, die Nachfrage dem Angebot anzupassen. Das Konzept existiert seit den 1980er Jahren (vgl. [56]). Im Kontext von Smart Grids und Microgrids gewinnt DSM aus zwei Gründen entscheidend an Bedeutung:

- (1) **Durch die zunehmende Anzahl an volatilen Energieerzeugern** wie Photovoltaik- und Windanlagen steigt das Potential, welches sich durch die Verschiebung von Lasten ergibt. Die Energieerzeugung solcher Anlagen ist nur begrenzt steuerbar und der Betrieb kann dazu führen, dass zu manchen Zeiten mehr Strom zur Verfügung steht, als benötigt wird, während zu anderen Zeiten kaum Strom von erneuerbaren Energieträgern vorhanden ist. Die Anpassung des Bedarfs an die Erzeugung stellt in solchen Fällen ein geeignetes Instrument dar, um die Effizienz in der Energieversorgung zu erhöhen.
- (2) **Durch die Digitalisierung der Energienetze** ergeben sich neue Möglichkeiten für die Nutzung von DSM. Erst durch die Installation von digitalen Stromzählern, den sogenannten Smart Metern, können die Verbrauchsdaten auf Haushaltsebene in regelmäßigen Zeitabständen ausgelesen und an den Energieversorger übertragen werden, so dass sich variable Stromtarife als Anreizsystem für DSM umsetzen lassen. Weiterhin sind „intelligente“ Haushaltsgeräte entwickelt worden, welche sich an eine digitale Kommunikationsinfrastruktur anschließen lassen. Dies ermöglicht eine automatisierte Verschiebung von Stromlasten, die in Echtzeit auf Veränderungen der Angebotsseite reagieren kann. Zu den zeitlich verschiebbaren Lasten gehören die Waschvorgänge von Spül- oder Waschmaschinen, der Betrieb von Trocknern und die Ladevorgänge von Elektroautos. Letztere machen aktuell noch einen kleinen Teil der Stromlasten aus, werden aber aller Voraussicht nach in den nächsten Jahren einen zunehmenden Faktor in den Stromnetzen (vgl. [57]) darstellen.

Die Anpassung des Bedarfs an die Erzeugung kann entweder lokal oder global betrachtet werden. Lokal gesehen ist es für einen einzelnen Haushalt mit einer PV-Anlage aus Sicht des Eigentümers vorteilhaft, die flexiblen Lasten so zu verschieben, dass der Eigenverbrauch erhöht wird. Wird dies in vielen Haushalten so gehandhabt und zudem der Strombezug soweit möglich geglättet, kann sich der Energieversorger auf einen gleichmäßigeren Bezug einstellen. Dies entspricht dem Konzept des zellularen Ansatzes (vgl. [1]), in welchem möglichst ausgeglichene Strombilanzen auf jeder Ebene angestrebt werden, um so zum einen die Netze in den niedrigen Spannungsebenen zu entlasten und die Notwendigkeit des Netzausbaus auf Niederspannungsebene zum Teil zu vermeiden. Zum anderen kann damit der Strombezug von Spitzenlastkraftwerken reduziert werden, welcher mit hohen Produktionskosten verbunden ist (vgl. [15]).

Ein anderer Ansatz stellt DSM in den Kontext von Real-Time-Pricing (RTP). Aufgrund der globalen Schwankungen in Angebot und Nachfrage wird Strom zu

variierenden Preisen gehandelt. Werden diese von den Energieversorgern durch zeitvariable Strompreise an den Verbraucher weitergegeben, so kann dieser durch DSM-Verfahren, welche die lokalen Stromkosten minimieren, zu global ausgeglicheneren Energiebilanzen beitragen.

In diesem Kapitel werden zwei DSM-Modelle für ein Microgrid beschrieben, in welchem die verschiebbaren Lasten ausgewählter Haushaltsgeräte automatisiert verschoben werden. Dabei wird einmal eine Glättung des lokalen Strombezugs und einmal die Minimierung der Stromkosten unter variablen Strompreisen angestrebt. Es wird untersucht, welche Effekte die jeweiligen Ansätze auf die Energiebilanzen, die Stromkosten und die CO₂-Emissionen des Microgrids haben. Dazu wird zunächst im Abschnitt 3.2 ein Überblick über die Grundlagen und verwandte Arbeiten gegeben. In Abschnitt 3.3 wird die Modellierung der verschiebbaren Lasten, der volatilen Erzeuger und der variablen Strompreise vorgestellt und die daraus resultierenden Optimierungsprobleme zur Verschiebung der Stromlasten abgeleitet. Zur Berechnung der optimalen Verschiebung werden zwei Lösungsansätze vorgestellt: In einem werden die flexiblen Lasten eines Haushaltes jeweils unabhängig vom den anderen Haushalten optimiert. In dem anderen, koordinativen Ansatz wird ein Multi-Agenten-System modelliert, in welchem zwischen den Haushalten über die Lastverschiebungen verhandelt wird. Der zweite Ansatz beruht grundlegend auf dem Artikel von Mohsenian-Rad et. al. [2]. Zur Analyse der Verfahren wird ein Microgrid simuliert, wozu die empirisch aufgezeichneten Daten des REFIT-Projektes [48] verwendet werden (Abschnitt 3.4). Die Ergebnisse der Simulationen werden in Abschnitt 3.5 vorgestellt und in Abschnitt 3.6 diskutiert. Der Abschnitt 3.7 gibt eine Zusammenfassung über die Erkenntnisse der Analyse.

Teile der Inhalte dieses Kapitels sind bereits auf wissenschaftlichen Konferenzen vorgestellt und in den entsprechenden Proceedings veröffentlicht worden. Dazu gehört eine Beschreibung des Ansatzes auf der Multikonferenz Wirtschaftsinformatik MKWI 2014 [58] und ein ausführlicher Literaturreview zu DSM [59], vorgestellt auf der Informatik 2015. Die Darstellung der Abschnitte 3.2 und 3.3 orientiert sich in Teilen an den genannten eigenen Arbeiten. Die Ansätze dieser Arbeiten wurden methodisch weiterentwickelt, an die beschriebenen Szenarien angepasst und die Effekte auf die Energiebilanzen durch Simulationen quantifiziert.

3.2 Grundlagen und verwandte Arbeiten

Im Kontext von Smart Grids sind vielfältige Forschungsfragen zu DSM aufgeworfen und analysiert worden. Diese umfassen beispielsweise die Einbettung in die Marktstrukturen, die Umsetzung in Optimierungsalgorithmen und den Aufbau einer geeigneten Kommunikationsinfrastruktur. In dieser Arbeit liegt der Fokus auf den Algorithmen zur Verschiebung der flexiblen Lasten und der Untersuchung der damit erreichbaren Effekte auf die lokale Energiebilanz im Microgrid. Zur Einordnung wird eine Übersicht über verwandte Arbeiten gegeben. Es wird dabei zwischen Optimierungsalgorithmen für DSM in einzelnen Haushalten und koordinativen Verfahren

zur Optimierung der Lastverschiebungen von mehreren Haushalten unterschieden.

3.2.1 DSM-Verfahren einzelner Haushalte

Für die Anwendung von DSM in einzelnen Haushalten sind verschiedene Algorithmen entwickelt worden. In der von mir durchgeführten Literaturanalyse [59] wurden 23 Artikel analysiert, welche sich auf DSM-Verfahren eingebettet in Energiemanagementsysteme von einzelnen Haushalte fokussieren. Dabei werden die Lastverschiebungen unabhängig von dem Bedarf anderer Haushalte bestimmt. Die wesentlichen Ergebnisse werden im Folgenden vorgestellt.

Die Zielsetzung von DSM in einzelnen Haushalten liegt in der Regel darin, Spitzenlasten zu vermeiden (vgl. [60–65]) oder als Reaktion auf variable Strompreise die Stromkosten zu reduzieren (vgl. [60,66–79]). Dabei wird teilweise angenommen, dass der Komfort der Nutzer bei einer Verschiebung abnimmt, was in der Optimierung berücksichtigt wird. Die Kombination von DSM mit erneuerbaren Energieträgern und die Erhöhung des Eigenverbrauchs wird in vergleichsweise wenigen der untersuchten Artikel betrachtet. Zu diesen gehören [61,70,80,81]).

Die Lastgänge, welche im Kontext von Haushalten auftreten, lassen sich in drei Kategorien unterteilen: (1) Nicht-verschiebbare Lastgänge, welche beispielsweise durch Kochaktivitäten oder die Nutzung von Lampen und Computern auftreten. Sie lassen sich nicht ohne Komforteinbußen verschieben. (2) Verschiebbare Lastgänge mit einem festen Lastprofil: Dazu gehören Waschgänge von Spül- und Waschmaschinen oder die Nutzung von Trocknern. Diese Haushaltsgeräte verursachen nach einer Erhebung der EnergieAgentur in Nordrhein-Westfalen rund 15% des Stromverbrauchs (vgl. [82]). Durch DSM kann der Startpunkt einer Anwendung verschoben werden. Dazu geben die Nutzer in der Regel ein Zeitintervall vor, in welchem der Vorgang durchgeführt werden soll. (3) Verschiebbare Lastgänge mit einem flexiblen Lastprofil: Dazu gehören der Ladeprozess eines Elektroautos, der Betrieb von Kühlgeräten wie Kühlschränken und Gefriertruhen sowie elektrische Heizungsanlagen. Gemäß der genannten Studie werden in NRW durchschnittlich weitere 15% des Gesamtstrombedarfs für Kühl- und Gefrierprozesse aufgewendet. Bei der Anwendung von DSM auf thermische Lasten muss gewährleistet sein, dass ein gewisses Temperaturlevel gehalten wird. Das führt in der Modellierung zu weitaus komplexeren Optimierungsproblemen, da Wärmeentwicklungen üblicherweise durch Differentialgleichungen modelliert werden. Daher werden thermische Lasten nur in wenigen der untersuchten Artikeln betrachtet (vgl. [66–70]), während sich die meisten der untersuchten Artikel auf verschiebbaren Lasten mit einem festen und teilweise unterbrechbaren Lastprofil beschränken (vgl. [60,61,71–73,76–81]).

Der Optimierungshorizont umfasst in der Regel 24 Stunden, wobei in den Simulationen meist zur Vereinfachung angenommen wird, dass die Lasten zu Beginn des Tages bekannt sind. Zur Lösung des aufgestellten Optimierungsproblems werden hauptsächlich evolutionäre Algorithmen und lineare Optimierung verwendet. Einige Artikel berücksichtigen Unsicherheiten über den Zeitpunkt der auftretenden Lasten oder die variierenden Strompreise und stellen stochastische Modelle zur Anwendung

von DSM auf: In [66] wird ein Zustandsraummodell zur Modellierung der thermische Lasten entwickelt, diese durch Kalman-Filter prognostiziert und mittels Model Predictive Control die Verschiebung berechnet. In [61] werden die Lasten als poissonverteilte Zufallsvariablen simuliert und das Optimierungsproblem zur Minimierung der Energiekosten durch die Verschiebung der Lasten als Markow-Entscheidungsprozess modelliert. In [72] richtet sich der Fokus auf die Strompreise und es wird angenommen, dass diese vorab nicht bekannt gegeben werden und eine robuste Optimierung zur Umsetzung von DSM unter ungewissen Stromtarifen vorgestellt.

Die genannten DSM Methoden sind in den untersuchten Artikeln jeweils auf künstlich erzeugten Datensätzen validiert worden. Eine Ausnahme stellt [80] dar, bei welchen reale Lastgänge verwendet und nur die Annahmen zur Flexibilität künstlich erzeugt wurden. Die verwendeten Kennzahlen sind zwischen den Artikeln nur begrenzt vergleichbar, da die Ergebnisse in hohem Maße von den Annahmen der simulierten Daten abhängen: In der DSM-Simulation aus [80] wird der Anteil des lokal erzeugten Stroms zur Deckung des Strombedarfs durchschnittlich um 16% durch DSM erhöht. In [68] werden die Stromkosten betrachtet und durch die Anwendung von DSM um 32% in der Simulation reduziert, in [75] um 75%, in [60] um 7%. In [60] wird zudem analysiert, wie sehr die Spitzenlasten durch den gewählten Ansatz gesenkt werden können. In der Simulation werden sie um 12,4% gesenkt. In [62] werden die Spitzenlasten um 32% reduziert.

Ein Vorteil haushaltsinterner Energiemanagementsysteme mit lokalem DSM liegt darin, dass die Daten über die verschiebbaren Lasten nicht weitergegeben werden müssen. Wird eine Minimierung der Stromkosten angestrebt und angenommen, dass die variablen Strompreise im Voraus bekanntgegeben werden, werden für die lokale Optimierung zudem keine Prognosen über den voraussichtlichen festen Strombedarf benötigt. Alle Informationen zur Optimierung der flexiblen Lasten sind in diesem Fall vor Ort gegeben und können autark optimiert werden. Ein Nachteil liegt jedoch darin, dass durch die flächendeckende Anwendung von lokalen DSM neue Peaks verursacht werden können, die zumindest kurzfristig zu negativen Effekten in der Auslastung der Energienetze führen können.

3.2.2 Koordinative DSM-Verfahren

Für die Anwendung von einem koordinativen DSM-Verfahren, bei welchen die Lastverschiebung mehrerer Haushalte durch einen verteilten Algorithmus bestimmt werden, sind in der durchgeführten Literaturrecherche [59] elf Artikel analysiert worden. Dabei wird jeweils vorausgesetzt, dass eine bidirektionale Kommunikationsinfrastruktur vorhanden ist, mit welcher Kostenfunktionen und voraussichtliche Stromlasten kommuniziert werden können. Die Bestimmung der Lastverschiebungen erfolgt über eine verteilte Optimierung in einem Multi-Agenten-System: In der Regel gibt es eine Steuerungseinheit, welche dem Energieversorger zugeordnet ist und das Optimierungsverfahren koordiniert. Die einzelnen Haushalte sind jeweils durch einen Agenten vertreten, der das lokale Energiemanagement des Haushalts koordiniert. Die Zielsetzung der koordinativen DSM-Verfahren liegt meist darin, einen

möglichst gleichmäßigen Strombezug des lokalen Grids zu erreichen und somit die Spitzenlasten zu glätten. Dabei wird der globale Optimalzustand für den Verbund der Haushalte angestrebt und nicht wie bei den individuellen Verfahren ein lokales Optima für die einzelnen Haushalte.

Ein Großteil der evaluierten Arbeiten [83–90] bezieht sich auf das Modell von Mohsenian-Rad et. al. [2], in welchem ein nicht-kooperatives Spiel zur Umsetzung von DSM vorgeschlagen wird. Dabei sollen Spitzenlasten vermieden und konkret die Peak-to-Average Ratio (PAR) minimiert werden. Es wird gezeigt, dass dies unter gewissen Voraussetzungen äquivalent zu einem konvexen Optimierungsproblem ist. Durch verteilte Best-Response-Algorithmen wird das globale Optimum erreicht, welches einem eindeutigen Nash-Gleichgewicht entspricht. Zur Aufstellung des Optimierungsproblems werden streng monoton wachsende, konvexe Kostenfunktionen genutzt, welche abhängig von dem prognostizierten Gesamtbedarf der involvierten Haushalte sind. Die Agenten der einzelnen Haushalte versuchen iterativ durch „Best Responses“ ihre eigenen Kosten zu minimieren. Zur Evaluation wird das Verfahren auf künstlich generierten Datensätzen erprobt und unter der Annahme, dass 50% der Lasten verschiebbar sind und ein flexibles Lastprofil haben, eine Reduktion der PAR von 2,34 auf 1,83 erreicht, dies entspricht einer Reduktion von knapp 22%. Eine Skizze dieses Ansatzes ist in Abb. 3.1 dargestellt.




Abbildung 3.1: Koordinative Verhandlungsstrategie zwischen den Haushalten H_1, \dots, H_N zur Bestimmung der Lastverschiebungen, Konzept und Darstellung in Anlehnung an [2]

Dieses Modell wird in anderen analysierten Arbeiten erweitert: In [83] wird ein Ansatz vorgestellt, bei welchem die Agenten nicht sequentiell, sondern simultan ihre Lastpläne anpassen. Dadurch wird eine schnellere Konvergenz erreicht. In [84] wird das Modell auf die Optimierung von Ladevorgängen von Elektrofahrzeugen angewendet. Dazu wird eine Erweiterung des Modells von einem atomaren Spiel hin zu einem nicht-atomaren Spiel mit unendlich vielen Elektrofahrzeugen vorgestellt und gezeigt, dass die Konvergenz gegen die optimale Lösung analytisch nur für das nicht-atomare Modell gezeigt werden kann. Nichtsdestoweniger werden die modellierten

Kosten auch für das endliche Modell auf den simulierten Daten wesentlich reduziert. In [85] werden statt einzelner Lasten Präferenzen zur zeitlichen Nutzung des Stroms erfasst und der Strom entsprechend zugeteilt. In zwei Artikeln [86,87] werden zusätzlich Stromspeicher betrachtet, mit welchen importierter Strom zwischengespeichert werden kann. In [87] ist zudem die Rückeinspeisung von bezogenem Strom möglich. Dies führt in der Simulation zwar zu einer weiteren Reduktion der modellierten Kosten, wirkt sich jedoch negativ auf die PAR aus. In dem Artikel [88] berücksichtigen die lokalen Agenten Unsicherheiten über den Stromverbrauch anderer Haushalte. Die Volatilität wird auf Basis von Normalverteilungen modelliert. Der Entscheidungsprozess über die Lastverschiebungen wird in jeder Zeiteinheit aktualisiert.

Zu den Ansätzen, welche sich nicht direkt auf [2] beziehen, gehören [91–93]. In [92] werden die Lastverschiebungen zur Glättung des Strombedarfs durch einen heuristischen Ansatz bestimmt, der auf der Theorie der Majorization beruht. In [93] wird mittels eines generativen Modells für jedes Haushaltsgerät gelernt, mit welcher Wahrscheinlichkeit eine flexible Last auftritt. Durch einen verteilten Algorithmus wird die Lastverschiebung bestimmt. In [91] wird ein DSM-Verfahren zur Optimierung von Ladeprozessen von Elektroautos vorgestellt, welche jeweils einem Haushalt zugeordnet sind. Wie in den bisher genannten Verfahren wird ein Multi-Agenten-System modelliert, um die Stromkosten zu minimieren, wobei angenommen wird, dass der variable Strompreis eines Zeitintervalls von der Nachfrage und dem Angebot in dem jeweiligen Zeitintervall abhängt. Dabei ist der jeweilige, anderweitige Strombedarf eines Haushalts unbekannt. Die Agenten bestimmen in diesem Ansatz durch Reinforcement Learning ihre Strategie zur Lastverschiebung. Zur Evaluation werden die Stromverbrauchsdaten des *CER Electricity Dataset*¹ zur Simulation von neun Haushalte verwendet, die Ladelasten der zugehörigen Elektrofahrzeuge werden künstlich generiert. Der Artikel ist der einzige Artikel in der durchgeführten Literaturrecherche, welcher empirische Verbrauchsdaten zur Evaluation eines koordinativen DSM-Ansatzes verwendet.

In allen genannten Artikeln werden ausschließlich verschiebbare Lasten mit einem flexiblen Lastprofil betrachtet, für welche der Bedarf innerhalb gewisser Leistungsgrenzen frei modelliert werden kann. Die fehlende Modellierung von Lasten mit einem festen Lastprofil und thermischer Lasten ist wahrscheinlich mit ein Grund für die fast ausschließliche Evaluation auf künstlich generierten Datensätzen. Bei einer Berücksichtigung von verschiebbaren Lasten mit festem Lastprofil ist der Raum der möglichen Strategien nicht notwendigerweise kompakt und konvex, so dass eine Erreichung eines globalen Optimums durch Best-Response-Algorithmen nicht wie in [2] gewährleistet ist. Trotzdem liegt es nahe, davon auszugehen, dass eine Reduktion der PAR erreicht wird. Inwiefern sich dieses Modell auch für verschiebbare Lasten mit festem Lastprofil eignet, ist bisher – soweit bekannt – weder theoretisch noch empirisch untersucht worden.

Der klare Vorteil von koordinativen DSM-Verfahren liegt darin, dass global optimiert wird. Auch können unerwünschte Nebeneffekte der individuellen Optimierung

¹ <http://www.ucd.ie/issda/data/commissionforenergyregulationcer/>. Zugriff am 29.01.2015

wie neue Peaks durch Lastverschiebungen vermieden werden. Dafür werden in allen genannten Verfahren monoton wachsende, stetig differenzierbare, konvexe Kostenfunktionen modelliert, welche von dem Gesamtbedarf abhängen. Es gibt Vorschläge, wie aus diesen Kostenfunktionen eine faire Stromkostenabrechnung für den Einzelnen erfolgen kann (vgl. [85]). Inwiefern dieses Modell Zuspruch bei den Energieversorgern und den Nutzern finden würde, ist – soweit bekannt – noch nicht analysiert worden. Ein Nachteil von koordinativen DSM-Verfahren entsteht durch den notwendigen Austausch von Verbrauchsdaten, bzw. angepasster Kostenfunktionen, aus welchen individuelle Verbrauchsdaten abgeleitet werden können. In [94, 95] werden daher datenschutzrechtliche Bedenken zu diesem Modell formuliert. Darüber hinaus werden Prognosen für den nicht verschiebbaren Strombedarf benötigt, welche stets mit gewissen Fehlerraten behaftet sind.

3.2.3 Förderung von DSM in Deutschland

Die Einführung von DSM wird in Deutschland durch gesetzliche Rahmenbedingungen gefördert. Mit dem Gesetz zur Digitalisierung der Energiewende soll der Ausbau der digitalen Infrastruktur vorangetrieben werden. Dazu wird der verpflichtende Einbau von Smart Metern ab 2020 vorgeschrieben². Bereits zuvor war die Installation von Smart Metern bei Neubauten und größeren Renovierungen verpflichtend³. Zudem wird der Netzbetreiber angewiesen, soweit möglich, variable Tarife anzubieten⁴ und für ansteuerbare und unterbrechbare Verbrauchseinrichtungen ein reduziertes Netzentgelt zu berechnen⁵. Variable Tarife könnten einen wesentlichen Anreiz darstellen, um Endverbraucher zur Nutzung von DSM zu motivieren.

Im Rahmen der Förderinitiative „E-Energy-Smart Grids in Germany“ sind in sechs Modellregionen Smart Grids aufgebaut worden, um Lösungen für eine nachhaltige und effiziente Energieversorgung zu erforschen (vgl. [96]). Dabei sind auch Feldversuche zur Anwendung von DSM durchgeführt worden: In dem E-Energy-Projekt „Modellstadt Mannheim“ (moma) wurde zunächst getestet, in welchem Maße Endverbraucher auf variable Stromtarife reagieren. Dafür wurde 73 Kunden zweistufige Stromtarife angeboten. Dies führt in dem Feldversuch zu einer durchschnittlichen Verschiebung von 6 bis 8% der elektrischen Last von Hoch- in Niedrigtarifphasen (vgl. [16]). In einem weiteren Feldversuch mit 671 Kunden wurden zeitvariable Tarife angeboten, welche stündlich variieren und einen Tag vorher bekannt gegeben wurden. Zudem sollten auch automatisierte Lastverschiebung mittels eines Energiemanagementsystems, dem sogenannten Energiebutler umgesetzt werden. Letztere waren „mangels standardisierter technischer Lösungen nicht machbar“ und konnten nur vereinzelt umgesetzt werden (vgl. [16]). In der Auswertung wurde eine Preiselastizität von -0,106 festgestellt, das heißt, dass bei einer 100% Preiserhöhung der Verbrauch um ca. 10,6% reduziert wurde. Auch in dem Projekt E-DeMa wurden in

² §31 MsbG

³ §21b EnWG

⁴ §40 EnWG

⁵ §14a EnWG

einem Feldversuch Lastverschiebungen mit variablen Tarifen getestet, wobei ein Teil der Verbraucher einige ausgewählte Geräte automatisch steuern lassen konnte, während der andere Teil auf tarifliche Anreize ausschließlich manuell reagierte. Durch das automatisierte Lastmanagement konnten mehr Kunden zu einer Verlagerungen ihres Verbrauches motiviert werden. Ohne Automatisierung wurden durchschnittlich 3,5% der Lasten in günstigere Tarifzeiten geschoben, mit Automatisierung 5% (vgl. [97]). Zu den gemeinsamen und zentralen Erkenntnissen gehört, dass durch moderne Informations- und Kommunikationstechnologien dezentrale Erzeuger und Verbraucher bereits heute besser aufeinander abgestimmt werden könnten.

3.2.4 Gewählte Ansätze für die Modellierung

Diese Arbeit evaluiert sowohl das Potential von individuellem DSM einzelner Haushalte im Microgrid als auch das Potential eines koordinativen DSM-Verfahrens im Microgrid mit empirischen Verbrauchsdaten. Dabei wird jeweils ein Algorithmus zur Minimierung der Stromkosten bei variablen Strompreisen und ein Algorithmus zur Senkung der Spitzenlasten umgesetzt und analysiert, welche Effekte auf die Energiebilanz, die Stromkosten und die CO₂-Emissionen daraus resultieren. Die Verfahren werden jeweils auf den REFIT-Daten evaluiert, welche bereits in Kapitel 2 zur Modellierung des Microgrids verwendet wurden. Die Auswertung von DSM auf empirisch aufgezeichneten Datensätzen, für welche die verschiebbaren Lasten separat vorliegen und entsprechend realistisch simuliert werden können, ermöglicht wirklichkeitsnahe Aussagen über die Effekte von DSM.

Die modellierten DSM-Verfahren beschränken sich auf die Verschiebung von Lasten mit einem festen Lastprofil. Diese Einschränkung erfolgt aus zwei Gründen: Zum einen handelt es sich bei einer solchen Verschiebung um ein technisch relativ einfach umsetzbares DSM, für welches keine weitere Daten wie die Raumtemperatur aufgezeichnet und modelliert werden müssen. Zum anderen geht die Verschiebung mit keinen Komforteinbußen einher, da der Nutzer die zeitlichen Restriktionen selbst wählt. Da in dem REFIT Datensatz der Verbrauch von großen Haushaltsgeräten wie Geschirrspülmaschinen, Waschmaschinen und Trocknern separat angegeben sind, können die verschiebbaren Lasten auf Basis dieser empirischen Daten simuliert werden. Soweit bekannt, wurden koordinative DSM-Verfahren bisher noch nicht für verschiebbare Lasten mit festem Lastprofil evaluiert.

Bei der Zielsetzung, die Stromkosten zu senken, werden *zeit*-abhängige Strompreise modelliert, welche mit den Day-Ahead-Preisen der Europäischen Strombörse EPEX SPOT SE verknüpft sind (vgl. Abschnitt 2.4.2). Bei der Zielsetzung, den Strombedarf zu glätten, werden die Strompreise nicht variiert. Dies ist für das koordinative Verfahren unkonventionell: In den verwandten Arbeiten werden die Kosten üblicherweise als quadratische Funktionen in Abhängigkeit der Gesamtlast modelliert, um so indirekt die PAR zu senken. Nach der aktuellen Gesetzgebung in Deutschland sind solche *last*-abhängige Strompreise jedoch nicht vorgesehen und da auch andere Vergütungsmodelle für die Flexibilität der verschiebbaren Lasten denkbar sind und zur Evaluation der möglichen Effekte auf die Energiebilanzen und die

CO₂-Emissionen keine Festlegung notwendig ist, werden die Stromkosten bei dieser Zielsetzung außen vor gelassen und direkt der Strombezug geglättet.

Die Modellierung der flexiblen Lasten und der Strompreise sowie die Algorithmen zur Lastverschiebung werden im nächsten Abschnitt vorgestellt.

3.3 Modellierung

Es wird ein Microgrid betrachtet, welches mehrere Haushalte und optional PV-Anlagen umfasst (vgl. Modellierung aus Kapitel 2). Im Folgenden werden der Stromverbrauch, die Solarstromerzeugung sowie die potentiellen Freiheitsgrade für die Anwendung von DSM formell modelliert. Dazu werden der Verbrauch und die Erzeugung jeweils durch diskrete Zeitreihen beschrieben, die den Verbrauch in 15 Minuten-Intervallen angeben. Die Optimierung erfolgt jeweils 24 Stunden im Voraus und unter der Annahme, dass die auftretenden Lasten in dieser Zeit bekannt sind.

3.3.1 Modellierung der Komponenten

3.3.1.1 Modellierung der Verbraucher

Sei N die Anzahl der Haushalte im Microgrid, \mathcal{A}_n die Menge an Verbrauchern in einem Haushalt $n \in \{1, \dots, N\}$ und y_{t,n_a} der Strombedarf eines Verbrauchers $a \in \mathcal{A}_n$ in dem Zeitintervall t eines Tages, $t \in \{1, \dots, 96\}$. Der gesamte Strombedarf für einen Haushalt n in dem Zeitintervall t ist dann

$$y_{t,n} = \sum_{a \in \mathcal{A}_n} y_{t,n_a}. \quad (3.1)$$

Der gesamte Strombedarf des Microgrids im Zeitintervall t ist

$$y_t = \sum_{n=1}^N \sum_{a \in \mathcal{A}_n} y_{t,n_a}. \quad (3.2)$$

Der Vektor $\mathbf{y}_n := (y_{1,n}, \dots, y_{96,n})$ bezeichne den Strombedarfsvektor für einen Tag eines Haushaltes n und $\mathbf{y} := (y_1, \dots, y_{96})$ den Strombedarfsvektor eines Tages für das gesamte Microgrid.

Das Optimierungspotential liegt darin, die Durchführung einiger Lasten zeitlich zu verschieben. In Abschnitt 3.2 wurde eine Unterscheidung zwischen drei Arten von Lasten vorgestellt: (1) nicht-verschiebbare Lasten, (2) verschiebbare Lasten mit einem festen Lastprofil und (3) verschiebbare Lasten mit einem flexiblen Lastprofil. Zu ersteren gehört der Stromverbrauch von Lampen, von Küchengeräten wie beispielsweise einem Herd oder einem Mixer. Die auftretenden Lasten werden genau zu dem Zeitpunkt benötigt, zu dem sie angefordert werden. Sie bieten daher kein Potential für die Anwendung von DSM. Der Bedarf eines Verbrauchers $a \in \mathcal{A}_n$ in einer Wohnung n mit nicht flexiblen Lasten wird mit einem Bedarfsvektor $\mathbf{y}_{n,a}$ modelliert, der sich nicht verschieben lässt. Die einzige Lösungsmenge zur Allokation

dieser Lasten ist dann durch den Bedarfsvektor des Verbrauches gegeben. Sie wird durch $\mathcal{Y}_{n,a} = \{\mathbf{y}_{n,a}\}$ beschrieben.

Die zweite Art von Lasten tritt bei Haushaltsgeräten auf, welche ein festes Lastprofil haben und bei welchen der Nutzer oftmals nicht auf eine direkte Ausführung besteht. Dies ist zum Beispiel der Waschvorgang einer Waschmaschine oder einer Spülmaschine. Solange die Wäsche in einem gewissen Zeitintervall fertig wird, treten bei dem Nutzer keine Komforteinbußen durch eine Lastverschiebung auf. Dies wird, wie folgt, modelliert: Sei $a \in \mathcal{A}_n$ ein Verbraucher in einer Wohnung n mit einer zeitlich verschiebbaren Last mit einem festen Lastprofil, welches durch eine Folge von Viertelstundenlasten $\bar{\mathbf{y}}_{n,a} = (\bar{y}_{1,n,a}, \bar{y}_{2,n,a}, \dots, \bar{y}_{\delta_{n,a},n,a})$ beschrieben wird. Die Dauer der Ausführung umfasse $\delta_{n,a}$ Viertelstunden. Diese Last soll innerhalb eines vom Nutzer vorgegebenen Intervall $[\alpha_{n,a}; \beta_{n,a}]$ ausgeführt werden, $\alpha_{n,a}, \beta_{n,a} \in \{1, \dots, 96\}$, $\alpha_{n,a} \leq \beta_{n,a} - \delta_{n,a} + 1$. Sei $\varepsilon_{n,a} = \delta_{n,a} - 1$, dann lässt sich die Menge der möglichen Realisierungen dieser Last darstellen als:

$$\mathcal{Y}_{a,n} = \left\{ \mathbf{y} \in \mathbb{R}_+^{96} \mid \begin{array}{l} \exists k \in [\alpha_{n,a}; \beta_{n,a} - \varepsilon_{n,a}] : \\ y_t = \begin{cases} \bar{y}_{t-k+1,n,a}, & \text{wenn } t \in [k, k + \varepsilon_{n,a}], \\ 0, & \text{sonst.} \end{cases} \end{array} \right\} \quad (3.3)$$

Die dritte Art von Lasten sind verschiebbare Lasten mit einem flexiblen Lastprofil. Zu diesen gehört zum Beispiel der Ladeprozess eines Elektroautos oder thermische Lasten wie sie durch elektrische HVAC-Anlagen (Heating, Ventilation and Air Conditioning) oder Kühlgeräte wie Kühlschränke oder Gefriertruhen auftreten. Diese Verbraucher erfordern eine spezifische Modellierung, welche bei thermischen Lasten i.d.R. mit komplexen Restriktionen einhergeht. In der vorliegenden Analyse wird auf die separate Modellierung dieser Lasten verzichtet. Sie gehen als nicht-verschiebbare Lasten in die Modellierung ein.

Die Menge der Möglichkeiten \mathcal{Y}_n , welche der Bedarf eines Haushaltes durch die Lastverschiebungen annehmen kann, ergibt sich aus den Kombinationen der Möglichkeiten für die einzelnen Lasten $a \in \mathcal{A}_n$:

$$\mathcal{Y}_n = \left\{ \sum_{a \in \mathcal{A}_n} \mathbf{y}_{n,a} \mid \mathbf{y}_{n,a} \in \mathcal{Y}_{a,n} \right\}. \quad (3.4)$$

Die Menge der Möglichkeiten \mathcal{Y} des Gesamtbedarfsvektors \mathbf{y} des Microgrids ergibt sich aus den Kombinationen der einzelnen Möglichkeiten aller Bedarfsvektoren im Microgrid:

$$\mathcal{Y} = \left\{ \sum_{n=1}^N \sum_{a \in \mathcal{A}_n} \mathbf{y}_{n,a} \mid \mathbf{y}_{n,a} \in \mathcal{Y}_{a,n} \right\}. \quad (3.5)$$

3.3.1.2 Modellierung der Stromerzeugung

Analog zu den nicht-verschiebbaren Verbrauchern lässt sich die Stromerzeugung der volatilen, nicht skalierbaren Energieerzeuger im Smart Grid modellieren. In dieser

Arbeit werden ausschließlich PV-Anlagen betrachtet: Sei M die Menge der PV-Anlagen und $s_{t,m}$ die Stromerzeugung von einer Anlage $m \in M$ in der t -ten Viertelstunde. Der Vektor $\mathbf{s}_m = (s_{1,m}, \dots, s_{96,m})$ beschreibt die nicht-steuerbare Stromerzeugung einer Anlage $m \in M$ an einem Tag.

Bei der Modellierung der volatilen Stromerzeugung wird unterschieden, ob es sich um Anlagen handelt, welche einem einzelnen Haushalt oder dem Microgrid als Ganzes zugeordnet sind. Dies ist von Bedeutung, da die gemeinsame Nutzung einer PV-Anlage sich nur koordinativ optimieren lässt. Bei der Anwendung von individuellem DSM werden daher PV-Anlagen modelliert, welche jeweils einem Haushalt zugeordnet sind. Bei der Anwendung eines koordinativen DSM wird eine gemeinsame PV-Anlage modelliert.

Ist eine Solaranlage $n \in M$ einem Haushalt zugeordnet, so wird der Solarstrom, welcher von diesem Haushalt nicht verwendet wird, in das Verteilernetz eingespeist: Es sei $f_{t,n} = \max(s_{t,n} - y_{t,n}; 0)$ der eingespeiste Strom im Zeitintervall t des Haushalts n und $f_t = \sum_n f_{t,n}$ die aggregierte Einspeisung der Haushalte in N . Ist dem Microgrid genau eine gemeinsame Solaranlage zugeordnet, so kann der Solarstrom von allen Haushalten bezogen werden und die Einspeisung berechnet sich aus $f_t = \max(s_t - y_t; 0)$, wobei s_t die Solarstromerzeugung der gemeinsamen Solaranlage im Zeitintervall t beschreibe.

3.3.2 Modellierung der Stromtarife

Es werden zwei Arten von Stromtarifen untersucht: (1) Bei der Zielsetzung, den Strombedarf zu glätten, wird ein fester Strompreis c^0 in Cent (ct) pro kWh modelliert, der unabhängig von der Zeit des Verbrauchs ist. (2) Bei der Zielsetzung, die Stromkosten unter RTP zu minimieren, werden zeitabhängige Strompreise c_t [ct/kWh] modelliert, welche von den Day-Ahead-Preisen der Europäischen Strombörse EPEX SPOT SE abhängen (vgl. Abschnitt 2.4.2). Die Spezifikation der Werte erfolgt in Abschnitt 3.4.2.

3.3.3 Modellierung der CO₂-Emissionen

Durch den Bezug von Strom aus dem Netz entstehen in den vorgelagerten Produktionsprozessen Treibhausgase. Der Emissionsfaktor des Strommixes gibt an, wie viele CO₂-Emissionen [g/kWh] durchschnittlich bei der Erzeugung einer Kilowattstunde Strom für den Endverbraucher emittiert werden (vgl. Abschnitt 2.3.3). Dabei ist der Emissionsfaktor von der Zusammensetzung des Strommixes abhängig. Durchschnittlich betrug der Emissionsfaktor 587 g/kWh im zweiten Quartals 2015 (vgl. [37]).

In der Evaluation der Verfahren wird einmal mit einem gleichbleibenden Emissionsfaktor gerechnet und einmal mit einem, welcher sich proportional zu den variablen Strompreisen verhält. Der Strompreis an der Strombörse ergibt sich aus Angebot und Nachfrage. Da die Volatilität des Angebots erheblich durch die erneuerbaren Energien getrieben ist, wird bei dem zweiten Ansatz angenommen, dass der Strom dann günstiger ist, wenn viel Strom aus erneuerbaren Energien zur Verfügung

steht und damit auch der Emissionsfaktor geringer ist. Die explizite Korrelation wird in Abschnitt 3.4.3 spezifiziert.

3.3.4 Optimierungsziele

Es werden zwei Optimierungsziele betrachtet, welche in den Experimenten getrennt ausgewertet werden.

3.3.4.1 DSM zur Glättung des Strombedarfs

Aus Sicht der Energieversorgers ist ein möglichst gleichmäßiger Strombedarf mit geringen Spitzenlasten vorteilhaft, um so den Bezug von teurem Strom aus Spitzenlastkraftwerken zu reduzieren. Um dies zu erreichen, wird der Strombezug im Microgrid optimiert: Sei $p_{t,n}$ der Strombezug eines Haushaltes n im Zeitintervall t eines Tages, angegeben in kWh. Dieser Wert berechnet sich aus der Differenz des Strombedarfs $y_{t,n}$ und der Solarstromerzeugung s_{t,m_n} einer ggf. zugehörigen Solaranlage $m_n \in M$:

$$p_{t,n} = \max(y_{t,n} - s_{t,m_n}; 0).$$

Der Vektor $\mathbf{p}_n = (p_{1,n}, \dots, p_{96,n})$ beschreibt die Bezugskurve eines Haushaltes n im Laufe des Tages. Bei der Umsetzung von DSM als individuelle Optimierung in einem Haushalt soll dieser Strombezug \mathbf{p}_n geglättet werden. Dafür wird in der vorliegenden Arbeit die Allokation $\mathbf{y}_n^* \in \mathcal{Y}_n$ gesucht, welche den lokalen Bezugsvektor \mathbf{p}_n in der $\|\cdot\|_2$ -Norm minimiert:

$$\mathbf{y}_n^* = \arg \min_{\mathbf{y}_n \in \mathcal{Y}_n} \|\mathbf{p}_n\|_2^2 = \arg \min_{\mathbf{y}_n \in \mathcal{Y}_n} \sum_{t=1}^{96} \max(y_{t,n} - s_{t,m_n}; 0)^2. \quad (3.6)$$

Der Gesamtbezug des Microgrids wird durch den Vektor $\mathbf{p} = (p_1, \dots, p_{96})$ dargestellt, welcher sich aus der Summe der Strombezüge der einzelnen Haushalte abzüglich einer ggf. dem Microgrid zugeordneten Solaranlage $m \in M$ darstellt:

$$p_t = \max\left(\sum_{n=1}^N p_{t,n} - s_{t,m_n}; 0\right).$$

Bei der Umsetzung eines koordinativen DSM soll der gesamte Strombezug \mathbf{p} des Microgrids geglättet werden. Dafür wird der Lastplan $\mathbf{y}^* \in \mathcal{Y}$ gesucht, welcher den Strombezugsvektor \mathbf{p} in der $\|\cdot\|_2$ -Norm minimiert:

$$\mathbf{y}^* = \arg \min_{\mathbf{y} \in \mathcal{Y}} \|\mathbf{p}\|_2^2 = \arg \min_{\mathbf{y} \in \mathcal{Y}} \sum_{t=1}^{96} (p_t)^2. \quad (3.7)$$

3.3.4.2 DSM zur Minimierung der Stromkosten bei RTP

Liegen variable Strompreise vor, ist es für die Nutzer attraktiv, DSM zu nutzen, um die Stromkosten zu reduzieren. Geht man davon aus, dass der Emissionsfaktor des

Strommixes mit dem variablen Strompreis korreliert ist, werden zudem die CO₂-Emissionen reduziert. Die variablen Stromkosten einer Wohnung n für einen Tag berechnen sich aus:

$$\sum_{t=1}^{96} c_{p,t} p_{t,n},$$

wobei $c_{p,t}$ wie zuvor den Strompreis im Zeitintervall t darstellt. Bei individuellem DSM wird nach dem Lastplan $\mathbf{y}^* \in \mathcal{Y}$ gesucht, für welchen die lokalen Kosten minimiert werden:

$$\mathbf{y}_n^* = \arg \min_{\mathbf{y}_n \in \mathcal{Y}_n} \sum_{t=1}^{96} c_{p,t} p_{t,n} = \arg \min_{\mathbf{y}_n \in \mathcal{Y}_n} \sum_{t=1}^{96} c_{p,t} \max(y_{t,n} - s_{t,m_n}; 0). \quad (3.8)$$

Die Reduktion der Stromkosten ist weitgehend unabhängig von anderen Haushalten, da die Strompreise durch den Verbrauch anderer Haushalte nicht beeinflusst werden.

Ist dem Microgrid eine gemeinsame Solaranlage m zugeordnet, von der alle Haushalte Strom beziehen können, kann die Nutzung des Solarstroms durch ein koordinatives DSM optimiert werden. In diesem Fall sollen durch die Lastverschiebungen die gesamten Stromkosten des Microgrids minimiert werden:

$$\mathbf{y}^* = \arg \min_{\mathbf{y} \in \mathcal{Y}} \sum_{t=1}^{96} c_{p,t} p_t = \arg \min_{\mathbf{y} \in \mathcal{Y}} \sum_{t=1}^{96} c_{p,t} \max\left(\sum_{n=1}^N p_{t,n} - s_{t,m}; 0\right). \quad (3.9)$$

3.3.5 Umsetzung der DSM-Verfahren

3.3.5.1 Individuelles DSM

Wird der Strombezug jeweils in einer Wohnung optimiert, ist die Anzahl der Möglichkeiten zur Lastverschiebung sehr eingeschränkt und wird in dieser Arbeit durch einen Test der vorhandenen Möglichkeiten zur Lösung von (3.6) und (3.8) bestimmt.

3.3.5.2 Koordinatives DSM

Zur Bestimmung der Lastverschiebungen bei dem koordinativen Modell werden die Verhandlungsstrategien aus [2] umgesetzt. Die lokalen Agenten der N Haushalte vertreten die Interessen der Wohnungen und werden als N nicht-kooperative Spieler angesehen. Das Optimierungspotential eines Spielers n ist in der Menge der Möglichkeiten \mathcal{Y}_n beschrieben (Gleichung (3.4)) und wird als die Menge der Strategien des Spielers n bezeichnet. Durch die Verhandlungen soll ein Nash-Gleichgewicht gefunden werden, das heißt eine Wahl der Strategien $(\mathbf{y}_1^*, \dots, \mathbf{y}_N^*) \in \mathcal{Y}_1 \times \dots \times \mathcal{Y}_N$, bei der es für keinen Spieler n sinnvoll ist, von seiner Strategie \mathbf{y}_n^* abzuweichen. Das lokale Optimierungsziel eines Spielers ist abhängig von der globalen Zielsetzung und der voraussichtlichen Auslastung im Microgrid. Innerhalb der Verhandlung werden die lokalen Optimierungsprobleme iterativ aktualisiert.

Glättung des Strombedarfs Der gesamte Stromimport des Microgrids \mathbf{p} soll geglättet werden. Das globale Optimierungsproblem ist in Gleichung (3.7) beschrieben. Sei für jeden Spieler n der Strombezug der anderen Spieler durch den Vektor $\mathbf{y}_{-n} = (y_{1,-n}, \dots, y_{96,-n})$ dargestellt. Dieser kann von dem Spieler n nicht beeinflusst werden; die „best response“ eines Spielers liegt darin, das lokale Optimum \mathbf{y}_n^* zur Allokation seiner Lasten zu finden:

$$\mathbf{y}_n^* = \arg \min_{\mathbf{y}_n \in \mathcal{Y}_n} \|\mathbf{p}\|^2 = \arg \min_{\mathbf{y}_n \in \mathcal{Y}_n} \sum_{t=1}^{96} \max(y_{t,-n} + y_{t,n} - s_t; 0)^2, \quad (3.10)$$

dabei sei s_t die Solarstromerzeugung der dem Microgrid als Ganzes zugeordnete Solaranlage im Zeitintervall t .

Jeder Spieler meldet zunächst eine mögliche zeitliche Verteilung seines Strombedarf \mathbf{y}_n an den Energieversorger, vertreten durch einen Koordinierungsagenten. Dieser berechnet daraus die aktuell gemeldete Gesamtlast \mathbf{y} und gibt diese sowie die voraussichtliche Solarstromerzeugung \mathbf{s} an die Spieler weiter, welche iterativ das lokale Optimierungsproblem zur Bestimmung ihrer Lasten (3.10) berechnen und im Anschluss die Gesamtlast \mathbf{y} updaten. Die lokalen Optimierungen der Spieler werden solange wiederholt, bis (fast) keine Anpassungen der Lastpläne mehr vorgenommen werden. Da das lokale Optimierungsproblem für jeden Spieler konvex ist, wird durch die iterativen Verhandlungen ein Nash-Gleichgewicht erreicht. Dieses Gleichgewicht entspricht nicht notwendigerweise dem globalen Optimum von (3.7), weshalb die Methodik nicht notwendigerweise individuellen Optimierungen überlegen sein muss. Der Algorithmus ist in Anlehnung an die Darstellung in [2] in Tab. 3.1 beschrieben.

Tabelle 3.1: DSM-Algorithmus für koordinatives DSM

Koordinativer DSM-Algorithmus	
– durchgeführt von jedem Spieler $n \in \{1, \dots, N\}$.	
1:	Initialisiere ein mögliches \mathbf{y}_n und gib es an koordinativen Agenten weiter.
2:	Bei Empfang von Gesamtlastplan \mathbf{y} von koordinativem Agenten,
3:	berechne $\mathbf{y}_{-n} = \mathbf{y} - \mathbf{y}_n$
4:	Wiederhole:
5:	In zufälligen Zeitabständen:
6:	Löse lokales Optimierungsproblem (3.10), bzw. (3.11).
7:	Wenn sich die Lösung von \mathbf{y}_n unterscheidet,
8:	führe ein Update der lokalen Planung \mathbf{y}_n durch,
9:	berechne den Gesamtlastplan $\mathbf{y} = \mathbf{y}_{-n} + \mathbf{y}_n$ neu,
10:	kommuniziere neuen Gesamtlastplan \mathbf{y} an die anderen Spieler.
11:	Wenn die Information über einen geänderten Gesamtlastplan eintrifft,
12:	führe ein Update von $\mathbf{y}_{-n} = \mathbf{y} - \mathbf{y}_n$ durch.
13:	Abbruch , wenn keine geänderten Lastpläne mehr empfangen werden.

Minimierung der Stromkosten Die gesamten Stromkosten des Microgrids sollen minimiert werden. Das angewendete Verhandlungsverfahren ist nahezu dasselbe wie zur Glättung des Strombedarfs mit dem Unterschied, dass sich die lokalen Optimierungsprobleme für jeden Spieler zur Bestimmung des lokalen Lastplans \mathbf{y}^* nun durch das globale Optimierungsproblem aus Gleichung (3.9) ableiten:

$$\mathbf{y}_n^* = \arg \min_{\mathbf{y}_n \in \mathcal{Y}_n} \sum_{t=1}^{96} c_{p,t} p_t = \arg \min_{\mathbf{y}_n \in \mathcal{Y}_n} \sum_{t=1}^{96} c_{p,t} \max(y_{t,-n} + y_{t,n} - s_t; 0), \quad (3.11)$$

wobei s^t wie zuvor die Solarstromerzeugung der dem Microgrid als Ganzes zugeordnete Solaranlage im Zeitintervall t sei. Letztlich wird in der Verhandlung hauptsächlich über die optimale Verteilung dieses Solarstroms verhandelt, da die zeitvariablen Strompreise selbst unabhängig von der Höhe der Lasten sind.

3.3.6 Konvergenzverhalten gegen globales Optimum

3.3.6.1 Lokale Optima bei individuellem DSM

Bei dem individuellen DSM wird nach einer jeweils optimalen Lösung des lokalen Optimierungsproblems gesucht. Dass bei der Zielsetzung, den Strombedarf zu glätten, die einzelnen Lösungen nicht zwingend zu der bestmöglichen Auslastung für einen Verbund von mehreren Haushalten führen, lässt sich durch ein einfaches Beispiel darstellen:

Bsp.1: Es werden zur Vereinfachung zwei Haushalte ohne PV-Anlage mit jeweils zwei Lasten, einer festen Last 1 und einer flexiblen Last 2, über den Zeitraum von zwei Zeitintervallen $t = 1, 2$ betrachtet: Sei $\mathbf{y}_{1,1} = (1; 0)$ der feste Stromverbrauch des Haushaltes 1 in den betrachteten Zeitintervallen und $\bar{\mathbf{y}}_{1,2} = (1)$ das feste Lastprofil der einzigen verschiebbaren Last dieses Haushaltes, welche in einem der beiden Zeitintervalle realisiert werden soll. Für den zweiten Haushalt sei $\mathbf{y}_{2,1} = (1; 0)$ der feste Stromverbrauch und $\bar{\mathbf{y}}_{2,2} = (3)$ die einzige verschiebbare Last in dem betrachteten Zeitraum. Durch die individuellen DSM-Verfahren werden die flexiblen Lasten so verschoben, dass der Strombezug des ersten Haushaltes durch den Vektor $\mathbf{y}_1 = (1; 1)$ beschrieben wird und der des zweiten Haushaltes durch $\mathbf{y}_2 = (1; 3)$. Es wird jeweils der bestmögliche lokale Zustand angenommen. Wird jedoch der gemeinsame Strombezug $\mathbf{y} = (2; 4)$ betrachtet, so wird deutlich, dass dies nicht der bestmöglichen globalen Auslastung $\mathbf{y}^* = (3; 3)$ entspricht, welche durch Lastverschiebungen möglich wäre. Die Lastverschiebungen des Beispiels sind graphisch in Abb. 3.2 dargestellt.

3.3.6.2 Nash-Gleichgewichte bei koordinativem DSM

Bei dem koordinativen Verfahren wird durch Verhandlungen nach dem globalen Optimum des Microgrids gesucht und in dem genannten Bsp. 1 würde dieses durch die iterative Anpassung der Lastpläne auch angenommen werden. In dem Artikel [2] wird gezeigt, dass dies bei speziellen Annahmen über die verschiebbaren Lasten

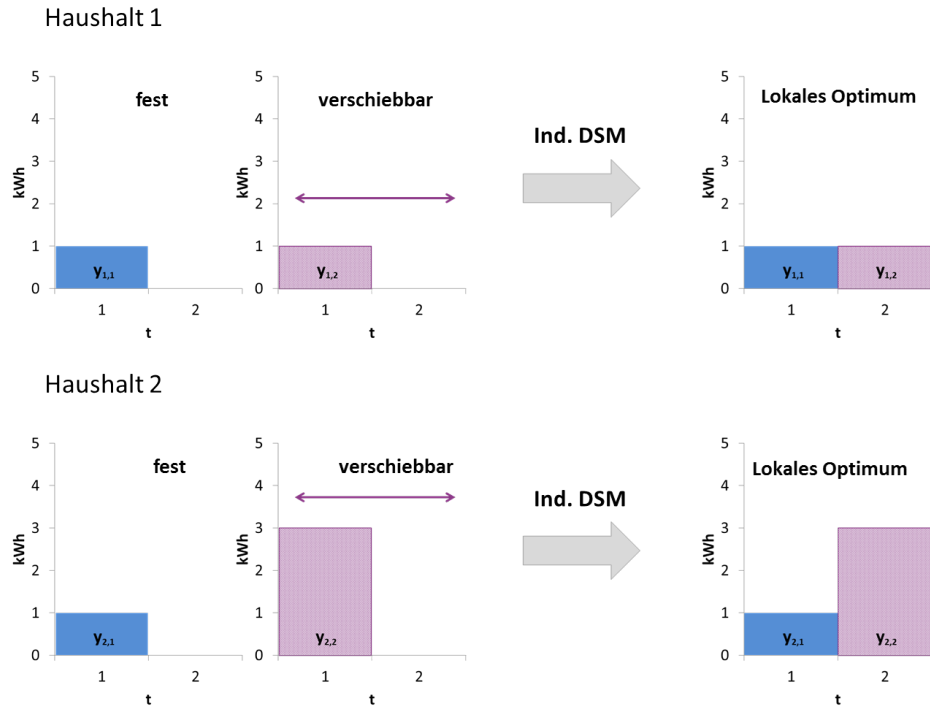


Abbildung 3.2: DSM Bsp. 1: Durch die individuelle Lastverschiebungen zweier Haushalte wird jeweils das lokale Optimum angenommen. Dies entspricht nicht der bestmöglichen globalen Auslastung.

immer der Fall ist. Dass dies jedoch nicht generell gilt, wenn verschiebbare Lasten mit einem festen Lastprofil berücksichtigt werden, wird an Beispiel 2 deutlich:

Bsp. 2: Es werden wieder zwei Haushalte ohne PV-Anlage über den Zeitraum von zwei Zeitintervallen $t = 1, 2$ betrachtet und es wird ein möglichst gleichmäßiger Strombezug angestrebt: Sei $\mathbf{y}_{1,1} = (0; 2)$ der feste Stromverbrauch des Haushaltes 1 und $\bar{\mathbf{y}}_{1,2} = (4)$ das feste Lastprofil der einzigen verschiebbaren Last dieses Haushaltes, welche in einem der beiden Zeitintervallen realisiert werden soll. Für den zweiten Haushalt sei der feste Stromverbrauch $\mathbf{y}_{2,1} = (1; 0)$ und der $\bar{\mathbf{y}}_{2,2} = (3)$ eine verschiebbare Last. Der vorläufige Gesamtverbrauch $\mathbf{y} = (8; 2)$ ergibt sich durch die Addition der Lastprofile, wenn beide Haushalte die flexible Last zunächst für $t = 1$ anmelden. In dem Beispiel beginnt der Haushalt 1 mit der Optimierung und verschiebt seine flexible Last in das zweite Zeitintervall. Dann ist bereits ein Nash-Gleichgewicht erreicht. Die alleinige Verschiebung der eigenen flexiblen Lasten führt bei keinem der beiden Haushalte mehr zu einer gleichmäßigeren Auslastung. Damit endet die koordinative Optimierung an dieser Stelle, obwohl das Nash-Gleichgewicht nicht der bestmöglichen globalen Auslastung $\mathbf{y}^* = (5; 5)$ entspricht, welche durch Lastverschiebungen möglich wäre. Das Beispiel 2 ist graphisch in Abb. 3.3 dargestellt. In diesem Beispiel würde das globale Optimum durch die individuellen DSM-Verfahren erreicht werden.

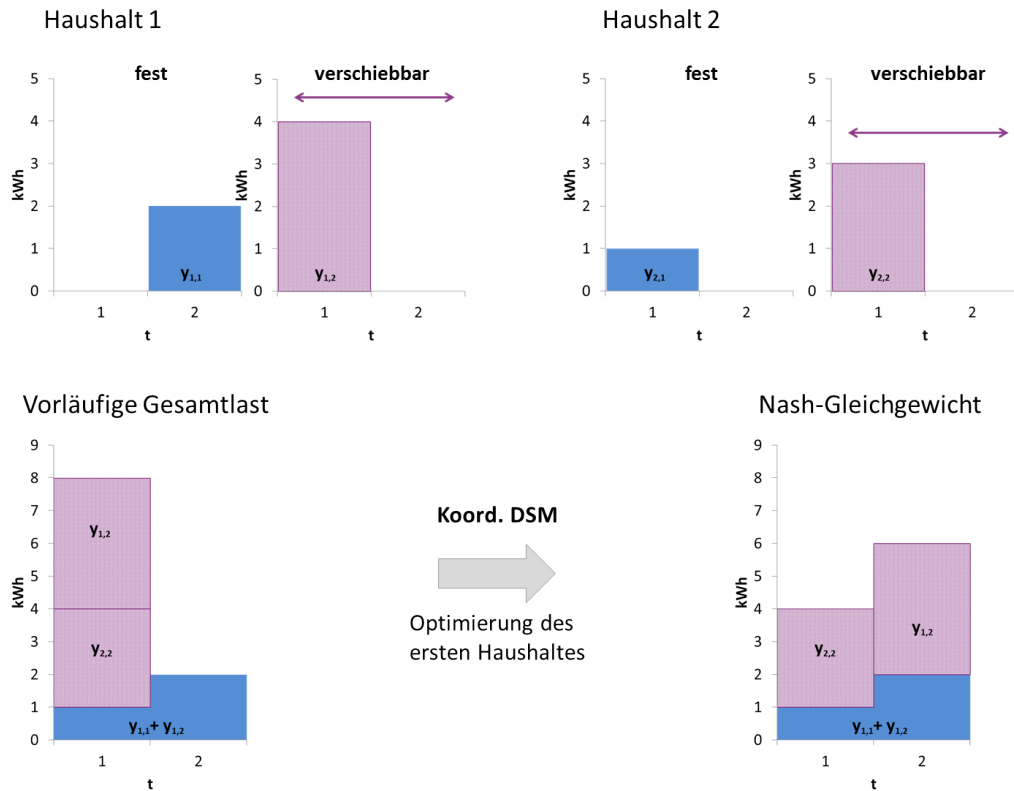


Abbildung 3.3: DSM Bsp. 2: Mögliche Lastverschiebung bei koordinativem DSM. Durch die Optimierung des ersten Haushaltes wird in den Verhandlungen ein Nash-Gleichgewicht erreicht, so dass es für keinen der beiden Haushalte mehr strategisch günstig ist, seinen Bedarf anzupassen. Dabei entspricht das Nash-Gleichgewicht nicht der bestmöglichen globalen Auslastung.

Die Beispiele zeigen, dass durch beide Verfahren nicht notwendigerweise die bestmöglichen Lastverschiebungen angenommen werden. In beiden Fällen kann man jedoch davon ausgehen, dass die Spitzenlasten insgesamt gesenkt werden. Im Folgenden werden beide Verfahren für jeweils ein knapp Jahr auf realen Verbrauchsdaten simuliert und ihre Effekte auf den Strombezug des Microgrids analysiert.

3.4 Simulation

3.4.1 Spezifikation der Komponenten

3.4.1.1 Spezifikation der Verbraucher

Die Verbraucher werden wie in Kapitel 2 mittels der Datenaufzeichnungen des Stromverbrauchs des REFIT Projekts [48] simuliert. Der Datensatz umfasst den Stromverbrauch von 20 Wohnungen in Großbritannien in 15 Minuten-Intervallen. Es werden

die Aufzeichnungen von zwölf Häusern (2, 3, 4, 6, 7, 10, 11, 15, 17, 18, 19 und 20) zur Simulation des Strombedarfs verwendet (vgl. Absatz 2.4.1.2). Der Datensatz umfasst 340 Tage, beginnend am 04. Juni 2014.

Zu jedem Haushalt sind die Verbrauchsdaten einzelner Haushaltsgeräte separat angegeben. Dazu gehören beispielsweise Geschirrspülmaschinen, Waschmaschinen, Trockner, Kühlschränke, Gefriertruhen, Fernsehgeräte, Toaster und Wasserkocher. Als flexible Lasten werden die Verbräuche von Geschirrspülmaschinen, Waschmaschinen und Trocknern identifiziert und zur Verschiebung durch die DSM-Verfahren freigegeben. Der Anteil der verschiebbaren Lasten liegt bei 10,9% des Gesamtverbrauchs. Dabei werden verschiedene Grade der Flexibilität verwendet: Ausgehend von der originalen Lastallokation wird angenommen, dass eine Last entweder jeweils um eine halbe Stunde, 1 Stunde, 2 Stunden oder 12 Stunden zeitlich nach vorne und hinten verschoben werden kann.

3.4.1.2 Spezifikation der Erzeuger

Wie in Abschnitt 2.4.1 wird ein Microgrid modelliert, in welchem eine PV-Anlage mit 18 kWp installierter Leistung integriert ist. Zur Simulation der Solarstromerzeugung werden die durchschnittlichen Tagesverläufe für jeden Monat gemäß der Simulation mit dem geographischen Informationssystem PVGIS des Joint Research Center der europäischen Kommission für eine solche Anlage in Hildesheim verwendet (vgl. Abschnitt 2.4.1).

3.4.2 Spezifikation der Stromtarife

Für den Stromtarif werden zwei Szenarien implementiert: Ein fester Strompreis und Real Time Pricing. Im ersten Fall wird angenommen, dass der Preis für eine kWh Strom einen konstanten Wert c_p über den gesamten Simulationszeitraum annimmt. Für die explizite Berechnung der Betriebskosten wird der durchschnittliche Preis in Deutschland in der zweiten Jahreshälfte 2015 verwendet: $c_p = 29,51 \text{ ct/kWh}$ (vgl. Abschnitt 2.4.2).

Für die Strompreise des RTP wird ebenfalls wie in Abschnitt 2.4.2 angenommen, dass die zeitvariablen Strompreise $c_{p,t}$ mit den Preisen der Day-Ahead Auction der Europäischen Strombörse (EPEX SPOT SE) verknüpft sind und einen Tag im Voraus bekannt gemacht werden. Dazu wurden die Handelspreise für den entsprechenden Zeitraum der Homepage der EPEX SPOT SE⁶ entnommen und mit einem Faktor von 7 multipliziert, da die Handelspreise an der Börse um ein Vielfaches niedriger sind als haushaltsübliche Strompreise. Zudem wird ausgeschlossen, dass der Strompreis einen niedrigeren Wert als die Einspeisevergütung annehmen kann, und der Strompreis daher mit 12,5 ct/kWh von unten beschränkt. Der durchschnittliche Strompreis beträgt somit 26,38 ct/kWh.

Die Einspeisevergütung wird in den DSM-Verfahren nicht berücksichtigt. Solange sie – wie modelliert – kleiner als der niedrigste Strompreis ist, hat sie keinen Einfluss

⁶ <https://www.epexspot.com/en/market-data>

auf die DSM-Verfahren. In der nachfolgenden Auswertung der Stromkosten wird mit einer Einspeisevergütung von $c_f = 11$ ct/kWh gerechnet (vgl. Abschnitt 2.4.2).

3.4.3 Spezifikation der CO₂-Emissionsfaktoren

Der durchschnittliche Emissionsfaktor des deutschen Strommixes lag im zweiten Quartals 2015 bei 587 g/kWh (vgl. [37]).

In der Auswertung werden davon ausgehend zwei Szenarien implementiert: Im ersten Fall wird angenommen, dass der Emissionsfaktor konstant über den ganzen Simulationszeitraum den Wert $e_p = 587$ g/kWh annimmt. Im zweiten Fall werden zeitvariable Strompreise modelliert und angenommen, dass der Emissionsfaktor sich proportional zu den variablen Strompreisen verhält: $e_{p,t} = 22,3 c_{p,t}$. Der Faktor 22,3 ist so gewählt, dass der durchschnittliche Emissionsfaktor weiterhin 587 g/kWh beträgt.

3.4.4 Kennzahlen

Zur Evaluation der Effekte der DSM-Algorithmen werden je nach Zielsetzung verschiedene Kennzahlen berechnet. Soll der Strombezug geglättet werden, werden, wie in Abschnitt 2.4.3 (1) die durchschnittliche tägliche Reduktion der Spitzenlasten (Peak Reduction, abgekürzt mit PR_d) und (2) die durchschnittliche tägliche Peak-to-Average Ratio (PAR_d) bestimmt:

$$PR_d := 1 - \frac{1}{K} \sum_{k=0}^{K-1} \frac{\max_{t \in [96k+1, 96(k+1)]} p_t}{\max_{t \in [96k+1, 96(k+1)]} y_t}, \quad (3.12)$$

$$PAR_d := \frac{1}{K} \sum_{k=0}^{K-1} \frac{\max_{t \in [96k+1, 96(k+1)]} p_t}{\frac{1}{96} \sum_{t=96k+1}^{96(k+1)} p_t}, \quad (3.13)$$

wobei $K = 340$ die Anzahl der Tage in der Simulation beschreibt. Bei der Minimierung der Stromkosten wird der durchschnittliche Strompreis für den importierten Strom angegeben:

$$c_p^\phi := \frac{\sum c_{p,t} p_t}{\sum p_t}. \quad (3.14)$$

Zusätzlich werden bei allen DSM-Verfahren die Effekte auf die Energiebilanzen untersucht und dazu angegeben, wie hoch die Anteile des Strombezugs und der Solarstromerzeugung und wie hoch der Anteil des eingespeisten Stroms im Verhältnis zum Gesamtbedarf sind (vgl. 2.4.3):

$$A_{PV} := \frac{\sum s_t}{\sum y_t}, \quad A_{\text{Netz}} := \frac{\sum p_t}{\sum y_t}, \quad A_{\text{FIT}} := \frac{\sum f_t}{\sum y_t}. \quad (3.15)$$

Aus diesen Werten können die Stromkosten und die CO₂-Emissionen rekonstruiert werden.




Abbildung 3.4: Simulation der DSM-Verfahren für einen Tag im Oktober unter Annahme, dass die Lasten um ± 12 Stunden verschoben werden dürfen.

3.5 Ergebnisse der Simulation

Die Simulation der DSM-Verfahren wurde für den Zeitraum von Juni 2014 bis Mai 2015 durchgeführt und ausgewertet.

Die Auswertung ist analog zu der Auswertung der optimierten BHKW-Steuerung in Abschnitt 2.5 aufgebaut. Zunächst werden die Effekte der Verfahren auf die Energiebilanzen an Beispieltagen veranschaulicht, um im Weiteren die Kennzahlen im Hinblick auf die Jahresenergiebilanzen, die Stromkosten, die Reduktion der Spitzenlasten und die CO_2 -Emissionen zu analysieren.

3.5.1 Energiebilanzen

3.5.1.1 Beispieltage

Die implementierten DSM-Verfahren haben unterschiedliche Effekte auf den Strombezug des Microgrids. In Abb. 3.4 ist für jedes Verfahren der simulierte Strombezug mit und ohne DSM für den 02. Oktober 2014 dargestellt. Der Zeitraum, in welchen

die flexiblen Lasten verschoben werden können, umfasste dabei in der Simulation ± 12 Stunden.

Für das individuelle DSM zur Glättung des Strombezugs ist eine Verschiebung der Lasten hin zur Mittagszeit erkennbar. Die absoluten Spitzenlasten werden nur geringfügig reduziert, da sie in diesem Fall nicht verschiebbar sind. Ein Peak am späteren Abend kann durch die Lastverschiebungen vermieden werden. Allerdings entsteht um die Mittagszeit ein neuer, wenn auch kleinerer Peak. Dies lässt sich damit erklären, dass die flexiblen Lasten der einzelnen Haushalte jeweils in die Mittagszeit gelegt werden, um einen größtmöglichen Teil dieser Lasten durch den zur Verfügung stehenden Strom der haushaltseigenen Solaranlage abzudecken. Dabei ist in einigen Fällen ein zusätzlicher Stromimport notwendig. Dadurch ergibt sich bei der Kumulation der Bezüge der neue Mittagspeak. Dieser Effekt wird bei dem koordinativen Verfahren durch die Verhandlungen vermieden. Der Strombezug wird insgesamt gleichmäßiger.

Bei den DSM-Verfahren mit Real-Time-Pricing, bei welchen die Lasten mit Blick auf die Stromkosten minimiert werden, werden die flexiblen Lasten in die Zeiten verschoben, in welchen die Strompreise am niedrigsten sind. An dem dargestellten Beispieltag liegen diese am frühen Morgen zwischen 04:00 Uhr und 05:00 Uhr vor. Zu diesem Zeitpunkt entsteht durch die Lastverschiebungen ein neuer Peak. Unterschiede zwischen dem individuellen DSM und dem koordinativen DSM sind nur zur Mittagszeit erkennbar, in welcher die gemeinsame Solaranlage bei dem koordinativen DSM-Verfahren effektiver genutzt werden kann als bei dem individuellen DSM.

3.5.1.2 Jahresbilanzen

Die in der Simulation, welche knapp ein Jahr (340 Tage) umfasst, ermittelten Kennzahlen sind in den Tabellen 3.2 und 3.3 dargestellt. Dabei sollen zunächst die Effekte auf die Zusammensetzung der Stromversorgung betrachtet werden: Ist keine PV-Anlage integriert, so ändert sich durch die DSM-Verfahren nichts daran, dass der komplette Strombedarf aus dem Netz gezogen wird. Da zudem die Lasten nur verschoben und nicht verkleinert werden, ändert sich auch die Menge des Stromimportes nicht. Die Effekte sind ausschließlich in der Verteilung der Lasten bemerkbar. In den weiteren Abschnitten werden die diesbezüglichen Effekte detailliert im Hinblick auf die Glättung des Strombezugs, die Stromkosten und die CO₂-Emissionen untersucht.

Sind PV-Anlagen Bestandteil des Microgrids, so reduziert sich der Strombezug A_{Netz} für alle DSM-Verfahren, da durch eine Erhöhung des Eigenverbrauchs sowohl der Strombezug geglättet wird, als auch die Stromkosten sinken. Bei dem individuellen DSM zur Glättung des Strombezugs sinkt der Anteil der Einspeisung von 8,9% auf 7,5%, wenn die Lasten ± 12 Stunden verschoben werden dürfen. Hier zeigt sich der Vorteil des koordinativen DSM: Der Anteil der Einspeisung wird bei diesem Verfahren von 3% auf 1,1% gesenkt, so dass nahezu die komplette Solarstromerzeugung vor Ort genutzt werden kann. Dabei wird deutlich, dass eine Solaranlage

Tabelle 3.2: Ergebnisse der Simulation der DSM-Verfahren zur Glättung des Strombedarfs

Microgrid		Kennzahlen					
DSM	Flexibilität	PV	A _{PV}	A _{Netz}	A _{FIT}	PAR _d	PR _d
ind.	–	–	–	100%	–	2,41	–
ind.	±0,5 h	–	–	100%	–	2,35	0,02
ind.	±1 h	–	–	100%	–	2,31	0,04
ind.	±2 h	–	–	100%	–	2,27	0,05
ind.	±12 h	–	–	100%	–	2,18	0,09
ind.	–	12×1,5 kWp	32,3%	76,6%	8,9%	2,92	0,09
ind.	±0,5 h	12×1,5 kWp	32,3%	76,4%	8,7%	2,84	0,12
ind.	±1 h	12×1,5 kWp	32,3%	76,2%	8,6%	2,79	0,14
ind.	±2 h	12×1,5 kWp	32,3%	76,0%	8,3%	2,73	0,15
ind.	±12 h	12×1,5 kWp	32,3%	75,2%	7,5%	2,66	0,19
koord.	–	–	–	100%	–	2,41	–
koord.	±0,5 h	–	–	100%	–	2,21	0,08
koord.	±1 h	–	–	100%	–	2,18	0,09
koord.	±2 h	–	–	100%	–	2,16	0,10
koord.	±12 h	–	–	100%	–	2,15	0,10
koord.	–	18 kWp	32,3%	70,7%	3,0%	3,21	0,10
koord.	±0,5 h	18 kWp	32,3%	70,3%	2,7%	2,95	0,17
koord.	±1 h	18 kWp	32,3%	70,1%	2,4%	2,93	0,19
koord.	±2 h	18 kWp	32,3%	69,7%	2,0%	2,91	0,20
koord.	±12 h	18 kWp	32,3%	68,8%	1,1%	2,95	0,20

effizienter genutzt wird, wenn sie nicht einem Haushalt, sondern einem Microgrid zugeordnet ist. Dieser Effekt zeigt sich auch bei den DSM-Verfahren zur Minimierung der Stromkosten bei RTP.

3.5.2 Glättung des Strombezugs

Die Kennzahlen zur Bewertung der Glättung des Strombezugs sind ebenfalls in Tab. 3.2 dargestellt. Sowohl mit individuellem DSM als auch dem koordinativen Verfahren können bei der Annahme, dass die flexiblen Lasten um ±12 Stunden verschoben werden dürfen, die Spitzenlasten um knapp 10% reduziert werden, wenn keine PV-Anlage vorhanden ist, und um weitere 10%, wenn eine PV-Anlage vorhanden ist. Größere Reduktionen sind aufgrund der nicht-verschiebbaren Lasten nicht möglich. Bemerkenswert ist, dass das koordinative Verfahren bereits durch Lastverschiebungen, welche auf den Zeitraum einer Stunde (±0,5 Stunden) eingegrenzt sind, die Spitzenlasten um knapp 8% senkt. Bei individuellem DSM wird hierbei nur eine Reduktion von 2-3% gegenüber den Spitzenlasten ohne DSM erreicht.

Zur Bewertung der PAR muss unterschieden werden, ob PV-Anlagen integriert sind. Ist keine PV-Anlage vorhanden, so tritt derselbe Effekt wie für die Reduktion der Spitzenlasten ein. Bei einer hohen Flexibilität von ±12 Stunden in den Last-

Tabelle 3.3: Ergebnisse der Simulation der DSM-Verfahren zur Minimierung der Stromkosten bei RTP

Microgrid		Kennzahlen				
DSM	Flexibilität	PV	A _{PV}	A _{Netz}	A _{FIT}	c_p^ϕ
ind.	–	–	–	100%	–	28,10
ind.	±0,5 h	–	–	100%	–	27,99
ind.	±1 h	–	–	100%	–	27,89
ind.	±2 h	–	–	100%	–	27,70
ind.	±12 h	–	–	100%	–	26,77
ind.	–	12×1,5 kWp	32,3%	76,7%	8,9%	28,48
ind.	±0,5 h	12×1,5 kWp	32,3%	76,4%	8,7%	28,36
ind.	±1 h	12×1,5 kWp	32,3%	76,2%	8,6%	28,25
ind.	±2 h	12×1,5 kWp	32,3%	76,1%	8,4%	28,05
ind.	±12 h	12×1,5 kWp	32,3%	76,1%	8,4%	26,95
koord.	–	–	–	100%	–	28,10
koord.	±0,5 h	–	–	100%	–	27,99
koord.	±1 h	–	–	100%	–	27,89
koord.	±2 h	–	–	100%	–	27,70
koord.	±12 h	–	–	100%	–	26,77
koord.	–	18 kWp	32,3%	70,7%	3,0%	28,67
koord.	±0,5 h	18 kWp	32,3%	70,3%	2,6%	28,56
koord.	±1 h	18 kWp	32,3%	70,0%	2,3%	28,45
koord.	±2 h	18 kWp	32,3%	69,6%	2,0%	28,26
koord.	±12 h	18 kWp	32,3%	68,8%	1,1%	27,35

verschiebungen wird sowohl mit den individuellen DSM-Verfahren als auch dem koordinativen Verfahren eine Reduktion der PAR um etwa 10% erreicht. Dies entspricht der maximal möglichen Reduktion. Bei dem koordinativen Verfahren wird die PAR bereits für eine Flexibilität von ±0,5 Stunden von 2,41 auf 2,21 (um 8%) reduziert, während die PAR bei dem individuellem DSM unter dieser Annahme nur auf 2,35 gesenkt wird. Dies entspricht einer Reduktion von 2,5%. Sind PV-Anlagen integriert, so ist die PAR insgesamt höher, da der durchschnittliche Netzbezug geringer wird. Die PAR wird jedoch bei den individuellen DSM-Verfahren mit steigender Flexibilität kontinuierlich verkleinert. Bei koordinativen Verfahren tritt der interessante Effekt ein, dass die Kennzahl zwar reduziert wird, eine Flexibilität von ±12 Stunden in den Lastverschiebungen jedoch in einer höheren PAR resultiert als bei einer Flexibilität von ±2 Stunden. Dies liegt an dem Effekt, dass bei der höheren Flexibilität der Netzbezug gesenkt wird und damit die PAR ansteigt, obwohl die Spitzenlasten selbst stärker reduziert werden.

Die Analyse führt zu zwei wichtigen Erkenntnissen: (1) Das koordinative Verfahren erreicht in der Simulation bereits bei einer sehr geringen zeitlichen Flexibilität von einer Stunde eine Spitzenlastreduktion von 8%. Um vergleichbare Ergebnisse für das individuelle DSM zu erhalten, muss eine Flexibilität von fast einem ganzem

Tabelle 3.4: Stromkosten bei DSM-Verfahren zur Glättung des Strombedarfs

Microgrid		Stromkosten				
DSM	Flexibilität	PV	c_p^0	Netzbezug	-export	\sum Strom
ind./koord.	beliebig	–	29.51 ct	13.029 €	–	13.029 €
ind.	–	12×1,5 kWp	29.51 ct	9.975 €	-432 €	9.543 €
ind.	±0,5 h	12×1,5 kWp	29.51 ct	9.951 €	-423 €	9.528 €
ind.	±1 h	12×1,5 kWp	29.51 ct	9.930 €	-416 €	9.515 €
ind.	±2 h	12×1,5 kWp	29.51 ct	9.901 €	-405 €	9.497 €
ind.	±12 h	12×1,5 kWp	29.51 ct	9.799 €	-367 €	9.433 €
koord.	–	18 kWp	29.51 ct	9.212 €	-148 €	9.064 €
koord.	±0,5 h	18 kWp	29.51 ct	9.164 €	-130 €	9.034 €
koord.	±1 h	18 kWp	29.51 ct	9.129 €	-117 €	9.012 €
koord.	±2 h	18 kWp	29.51 ct	9.083 €	-100 €	8.983 €
koord.	±12 h	18 kWp	29.51 ct	8.957 €	-53 €	8.904 €

Tag angenommen werden. (2) Die maximal mögliche Reduktion der Spitzenlasten beträgt wegen der nicht-verschiebbaren Lasten 10%. Dieser Wert wird für das koordinative Verfahren bereits bei einer Flexibilität von ±2 Stunden erreicht. Dies ist ein Indiz dafür, dass das koordinative Verfahren auch bei verschiebbaren Lasten mit festem Lastprofil ein gutes Instrument zur Senkung der Spitzenlasten im Microgrid darstellt, auch wenn theoretisch allgemein keine Konvergenz gegen das globale Optimum nachgewiesen werden kann.

3.5.3 Reduktion der Stromkosten

Die Stromkosten unter der Zielsetzung, den Strombedarf zu glätten, sind in Tab. 3.4 dargestellt. Sie werden durch die Anwendung von DSM-Verfahren nur dann reduziert, wenn zugleich PV-Anlagen integriert sind und somit der Eigenverbrauch erhöht wird. Dies führt bei den individuellen DSM-Verfahren zu einer maximalen Einsparung von 1,2%, bei den koordinativen Verfahren zu einer Einsparung von maximal 1,8%. Im lukrativsten Fall – bei koordinativem DSM und gemeinsamer PV-Anlage – werden die Stromkosten des gesamten Microgrids um 160 € reduziert, was eine sehr geringe Einsparung für jeden einzelnen Haushalt bedeutet. Um ein solches DSM umzusetzen, müssten weitere finanzielle Anreize angeboten werden. Mögliche Optionen werden in der Diskussion (Abschnitt 3.6) erörtert.

Deutlichere Effekte auf die Stromkostenbilanzen werden erwartungsgemäß durch die DSM-Verfahren erreicht, welche die Zielsetzung haben bei RTP die Stromkosten zu minimieren. Die Bilanzen der Simulation sind in Tab. 3.5 dargestellt. Sind keine PV-Anlagen integriert, so entspricht die koordinative Optimierung den individuellen DSM-Verfahren, da die Strompreise unabhängig von den Lasten sind. Bei einer zeitlichen Flexibilität von ±12 Stunden werden die Stromkosten durch die DSM-Verfahren um 587 € reduziert. Damit werden immerhin 5% der Kosten eingespart. Allerdings ist dieser Wert bei einer eingeschränkteren Flexibilität von ±2

Tabelle 3.5: Stromkosten bei DSM-Verfahren zur Minimierung der Stromkosten und RTP

Microgrid		Stromkosten				
DSM	Flexibilität	PV	c_p^ϕ	Netzbezug	-export	\sum Strom
ind./koord	–	–	28,10 ct	12.407 €	–	12407 €
ind./koord	$\pm 0,5$ h	–	27,99 ct	12.359 €	–	12.359 €
ind./koord	± 1 h	–	27,89 ct	12.314 €	–	12.314 €
ind./koord	± 2 h	–	27,70 ct	12.231 €	–	12.231 €
ind./koord	± 12 h	–	26,77 ct	11.820 €	–	11.820 €
ind.	–	$12 \times 1,5$ kWp	28,48 ct	9.625 €	-432 €	9.193 €
ind.	$\pm 0,5$ h	$12 \times 1,5$ kWp	28,36 ct	9.560 €	-422 €	9.138 €
ind.	± 1 h	$12 \times 1,5$ kWp	28,25 ct	9.506 €	-416 €	9.090 €
ind.	± 2 h	$12 \times 1,5$ kWp	28,05 ct	9.422 €	-409 €	9.013 €
ind.	± 12 h	$12 \times 1,5$ kWp	26,95 ct	9.052 €	-408 €	8,644 €
koord.	–	18 kWp	28,67 ct	8.951 €	-148 €	8.804 €
koord.	$\pm 0,5$ h	18 kWp	28,56 ct	8.860 €	-127 €	8.733 €
koord.	± 1 h	18 kWp	28,45 ct	8.791 €	-113 €	8.678 €
koord.	± 2 h	18 kWp	28,26 ct	8.688 €	-96 €	8.592 €
koord.	± 12 h	18 kWp	27,35 ct	8.310 €	-56 €	8.254 €

Stunden deutlich kleiner: In diesem Fall werden die Stromkosten nur um insgesamt 176 € reduziert. Sind PV-Anlagen integriert, so werden die gesamten Stromkosten durch beide DSM-Verfahren jeweils maximal um 550 € gesenkt. Dies entspricht einer Stromkostenreduktion von 6%. Dafür wird eine zeitliche Flexibilität der verschiebbaren Lasten von ± 12 Stunden vorausgesetzt. Liegt diese bei ± 2 Stunden beträgt die Reduktion 2,0 – 2,4%.

Insgesamt zeigt sich, dass die Stromkosten durch die DSM-Verfahren nur eingeschränkt reduziert werden können und nach den Ergebnissen der Simulationen für eine Kostenreduktion von mehr als 5% eine hohe Flexibilität in der Allokation der verschiebbaren Lasten erforderlich ist. Es wird darüber hinaus deutlich, dass die gemeinsame Nutzung einer PV-Anlage zu einer insgesamt deutlich vorteilhafteren Kostenbilanz führt als die Nutzung von einzelnen PV-Anlagen.

3.5.4 Reduktion der CO₂-Emissionen

Mit den CO₂-Emissionen verhält es sich ähnlich wie mit der Reduktion der Stromkosten: Nimmt man an, dass der Emissionsfaktor des Strommixes e_p über den Simulationszeitraum konstant ist, so kann mit den DSM-Verfahren zur Glättung des Strombezugs nur bei vorhanden PV-Anlagen eine Reduktion durch die Erhöhung des Eigenverbrauchs erreicht werden. Bei den individuellen Verfahren führt dies zu einer maximalen Reduktion der CO₂-Emission um 1,8% und bei den koordinativen Verfahren um 2,8%. Die detaillierte Aufschlüsselung der CO₂-Emissionen bei verschiedenen Annahmen zur zeitlichen Flexibilität der verschiebbaren Lasten ist in Tab. 3.6 gegeben. Unter Verwendung des Emissionsfaktors $e_p = 587$ g/kWh führen

Tabelle 3.6: CO₂-Emissionen bei DSM-Verfahren zur Glättung des Strombedarfs

Microgrid		CO ₂ -Emissionen		
DSM	Flexibilität	PV	e_p	CO ₂
ind./koord.	beliebig	–	587 g/kWh	25,92 t
ind.	–	12×1,5 kWp	587 g/kWh	19,84 t
ind.	±0,5 h	12×1,5 kWp	587 g/kWh	19,79 t
ind.	±1 h	12×1,5 kWp	587 g/kWh	19,75 t
ind.	±2 h	12×1,5 kWp	587 g/kWh	19,69 t
ind.	±12 h	12×1,5 kWp	587 g/kWh	19,49 t
koord.	–	18 kWp	587 g/kWh	18,32 t
koord.	±0,5 h	18 kWp	587 g/kWh	18,23 t
koord.	±1 h	18 kWp	587 g/kWh	18,16 t
koord.	±2 h	18 kWp	587 g/kWh	18,07 t
koord.	±12 h	18 kWp	587 g/kWh	17,82 t

die DSM-Verfahren zur maximalen Reduktion des CO₂-Ausstoßes um 0,35 t, bzw. 0,51 t. Wird die zeitliche Flexibilität der verschiebbaren Lasten in der Simulation auf ±2 Stunden eingeschränkt, so werden durch das koordinative Verfahren immerhin noch 1,4% der CO₂-Emissionen vermieden.

Nimmt man an, dass der Emissionsfaktor des Strommixes im Verteilernetz je nach Auslastung variiert und man die Spezifikation aus Abschnitt 3.4.3 verwendet, so wird der durchschnittliche Emissionsfaktor e_p^0 für den bezogenen Strom durch die DSM-Verfahren zur Minimierung der Stromkosten in demselben Verhältnis wie der durchschnittliche Strompreis c_p^0 gesenkt. Die Ergebnisse dieser Simulation sind in Tab. 3.7 dargestellt: Bei einer Flexibilität von ±2 Stunden wird für das Microgrid ohne PV-Anlage durch beide DSM-Verfahren eine Reduktion der CO₂-Emissionen um 1,4% erreicht. Dies entspricht 0,4 t CO₂. Bei einer Flexibilität von ±12 Stunden erhöhen sich die vermiedenen CO₂-Emissionen auf 1,3 t (4,7%). Sind PV-Anlagen integriert, beträgt die Reduktion durch die DSM-Verfahren bei der maximal angenommenen Flexibilität von ±12 Stunden 6 – 7%. Dabei ist anzumerken, dass die Proportionalitätskonstante, mit welcher der Emissionsfaktor mit den RTP in der Modellierung verknüpft wurde, tendenziell überschätzt wurde, da die absoluten Angaben der CO₂ Emissionen für das Microgrid ohne DSM höher sind als mit dem Durchschnittswert.

Die Analyse zeigt, dass mit DSM-Verfahren bei zeitvariablen Stromtarifen, welche den voraussichtlichen Emissionsfaktor des Strommixes widerspiegeln, eine Reduktion der globalen CO₂ Emissionen in der Stromversorgung erreicht wird. Die Verschiebung des flexiblen Bedarfs führt dazu, dass mehr Strom in Zeiten verbraucht wird, in denen mehr Strom aus erneuerbaren Energien zur Verfügung steht. Bei den DSM-Verfahren zur Glättung des Strombedarfs war die erreichte Reduktion der CO₂-Emissionen in der Simulation deutlich geringer. Dabei wurden nur die lokalen Effekte auf die CO₂-Emissionen modelliert, da nicht bekannt ist, wie sich eine Glättung des Strombedarfs auf die globalen Energiebilanzen auswirkt – auch wenn

Tabelle 3.7: CO₂-Emissionen bei DSM-Verfahren zur Minimierung der Stromkosten und RTP

Microgrid		CO ₂ -Emissionen		
DSM	Flexibilität	PV	e_p^{ϕ}	CO ₂
ind./koord.	–	–	627 g/kWh	27,67 t
ind./koord.	±0,5 h	12×1,5 kWp	624 g/kWh	27,56 t
ind./koord.	±1 h	12×1,5 kWp	622 g/kWh	27,46 t
ind./koord.	±2 h	12×1,5 kWp	618 g/kWh	27,28 t
ind./koord.	±12 h	12×1,5 kWp	597 g/kWh	26,36 t
ind.	–	12×1,5 kWp	635 g/kWh	21,46 t
ind.	±0,5 h	12×1,5 kWp	632 g/kWh	21,32 t
ind.	±1 h	12×1,5 kWp	630 g/kWh	21,20 t
ind.	±2 h	12×1,5 kWp	625 g/kWh	21,01 t
ind.	±12 h	12×1,5 kWp	601 g/kWh	20,19 t
koord.	–	18 kWp	639 g/kWh	19,96 t
koord.	±0,5 h	18 kWp	637 g/kWh	19,76 t
koord.	±1 h	18 kWp	634 g/kWh	19,60 t
koord.	±2 h	18 kWp	630 g/kWh	19,37 t
koord.	±12 h	18 kWp	610 g/kWh	18,53 t

angenommen wird, dass dies ein erwünschter Effekt ist.

3.6 Diskussion

In der Auswertung der Simulationsergebnisse wurden die Effekte der implementierten Verfahren auf die Energiebilanzen im Microgrid, die Glättung des Strombezugs, die Stromkosten und die CO₂-Emissionen untersucht. Da in den jeweiligen Algorithmen und Auswertungen jedoch gewisse Annahmen zur Vereinfachung oder zur Abschätzung der Effekte getroffen wurden, werden im Folgenden weitergehende Fragen im Kontext von DSM aufgezeigt und diskutiert.

3.6.1 Zielsetzung von DSM

Die übergeordnete Zielsetzung von DSM sollte im Hinblick auf die CO₂-Emissionen darin liegen, durch Lastverschiebungen erneuerbare Energien effizienter in die Stromnetze zu integrieren. In dieser Arbeit wurden dazu zwei unterschiedliche Ansätze betrachtet:

- (1) **Glättung des lokalen Strombezugs.** Dieser Ansatz ist besonders geeignet, um kleine dezentrale erneuerbare Energieerzeugungsanlagen effizient einzubinden. Sowohl der Strombezug als auch die mögliche Einspeisung der Erzeugungsanlagen werden durch diesen Ansatz geglättet und auf diese Weise die Verteilernetze entlastet.

(2) Anpassung an übergeordnete Vorgaben in Form von Stromtarifen.

Dieser Ansatz ist dagegen geeignet, große Anlagen erneuerbare Energien wie Photovoltaik-Freiflächenanlagen oder Windparks in die Stromnetze besser einzubinden. Bei diesen ist zeitweise mit hohen Einspeiseleistungen zu rechnen und bei einer entsprechenden Gestaltung der Strompreise wird die Nachfrage durch die Anwendung von DSM gezielt zu diesen Zeiten erhöht. Dabei sind jedoch mögliche Rückkopplungseffekte zu berücksichtigen.

Für die weitere Entwicklung von DSM bedarf es einer makroökonomischen Bewertung dieser Ansätze.

3.6.2 Konzeption der Stromtarife

Es bedarf finanzieller Anreize, um die Bewohner von Haushalten zu motivieren, DSM Verfahren zu nutzen und den verschiebbaren Lasten möglichst hohe zeitliche Freiheitsgrade zuzugestehen. Bei der Zielsetzung den Strombedarf zu glätten, wird in den verwandten Arbeiten i.d.R. davon ausgegangen, dass der Energieversorger *last-variable* Stromtarife verwendet, welche in Abhängigkeit von der Gesamtlast streng monoton wachsend und konvex sind. Diese Annahme ist insbesondere bei einem koordinativen DSM kritisch, weil damit der zu bezahlende Strompreis von dem Verhalten der anderen Nutzer im Microgrid abhängt. Der hohe Spitzenlastverbrauch eines einzelnen Haushaltes kann zu hohen Stromkosten für alle Haushalte im Microgrid führen, was zu einem Akzeptanzproblem solcher Strompreise führen wird. Daher werden im Folgenden andere Tarifmodelle skizziert, mit welchen der Energieversorger die Flexibilität seiner Kunden honorieren könnte:

- (1) Es werden Boni für Kunden eingeführt, welche ein Energiemanagement mit DSM nutzen. Die Höhe der Boni sollte dabei von der Menge des flexiblen Strombedarfs und der Flexibilität dieses Bedarfs abhängen. Ein solches Anreizmodell könnte sowohl bei individuellem als auch bei koordinativem DSM genutzt werden.
- (2) Bei einem individuellen DSM kann der Energieversorger alternativ Stromtarife anbieten, welche einen sogenannten Leistungspreis enthalten. Dieser wird aus der in einem bestimmten Zeitraum (z.B. einem Monat) maximal angeforderten Leistung (gemittelt über 15 Minuten) berechnet. Solche Stromtarife sind für Gewerbekunden oder industrielle Großverbraucher bereits üblich, um Spitzenlasten in der Auslastung der Stromnetze zu vermeiden (vgl. [98]).

Bei den DSM-Verfahren zur Minimierung der Stromkosten wird angenommen, dass zeitvariable Stromtarife vorliegen. In der Modellierung wurden diese mit den Day-Ahead-Preisen der europäischen Strombörse verknüpft. Dies führt in der Simulation zu einer Verschiebung der Lasten in die Zeiträume, in welchen der Energieversorger den Strom günstiger erhalten konnte. Dabei sind keine möglichen Rückkopplungseffekte bei einem flächendeckendem Einsatz der Methodik berücksichtigt, wenn sich die Auslastung in Zeiträumen niedriger Strompreise so stark erhöht, dass

der Strom in diesen Zeiten in großen Mengen nachgekauft werden muss und der Handelspreis im Intraday-Handel entsprechend anzieht. Um solche Rückkopplungseffekte zu vermeiden, müssten diese bereits auf Basis entsprechender Simulationen in die zeitvariablen Stromtarife eingepreist sein. Dazu sei angemerkt, dass solche Effekte erst dann eintreten, wenn eine große Menge an verschiebbaren Lasten durch DSM-Verfahren reguliert werden.

3.6.3 Unsicherheiten in der Optimierung

Bei der Glättung des Strombezugs durch DSM werden Prognosen über den voraussichtlichen Strombedarf benötigt - zumindest über den Zeitraum, in welchen die Lasten potentiell verschoben werden können. Solche Bedarfsprognosen sind i.d.R. fehlerbehaftet, wie bereits bei der Optimierung des BHKWs angemerkt und in Kapitel 4 ausführlich untersucht wird. Dies führt zu der weitergehenden Forschungsfrage, wie diese Unsicherheiten in den DSM-Verfahren berücksichtigt werden können und welche Ergebnisse unter dieser Berücksichtigung möglich sind.

Es gehört zu den Vorteilen der DSM-Verfahren zur Minimierung der Stromkosten, dass die optimale Bestimmung der Lastverschiebung für den lokalen Nutzer unabhängig von anderen Lasten ist. Zur Bestimmung einer Lastverschiebung sind nur Informationen über die verschiebbare Last selbst (Lastprofil und Flexibilität) sowie die Strompreise für den Optimierungszeitraum notwendig. Es werden keine Prognosen über den weiteren Strombedarf benötigt. Sind keine PV-Anlagen integriert, ist ein individuelles DSM somit ohne weitere Abhängigkeiten und Unsicherheiten umsetzbar. Die Unsicherheit liegt auf Seiten des Stromanbieters, welcher die variablen Strompreise auf Basis der erwarteten Auslastung erstellt.

3.6.4 Kommunikationsinfrastruktur und Datensicherheit

Zur Nutzung von DSM-Verfahren muss eine entsprechende digitale Kommunikationsinfrastruktur aufgebaut sein. Mit dem Gesetz zur Digitalisierung der Energiewende⁷ wird der Rollout der notwendigen Smart Metern bereits vorangetrieben. Darüber hinaus bedarf es einer Verbreitung von haushaltsinternen Energiemanagementsystemen und programmierbaren Haushaltsgeräten. Dafür ist eine Vereinheitlichung und Standardisierung der entsprechenden Schnittstellen essentiell.

Die von Smart Metern erfassten Verbrauchsdaten sind private, personenbezogene Daten. Eine Verwendung dieser zur Optimierung der Netzauslastung bedarf daher hoher Standards hinsichtlich der Datensicherheit. Einige Forschern sehen die Anwendung von DSM daher kritisch (vgl. [99]). Insbesondere bei den koordinativen DSM-Verfahren werden private Verbrauchsdaten weitergegeben: In den Verhandlungen wird zum einen dem Energieversorger der voraussichtliche Strombedarf gemeldet, zum anderen werden die jeweils angepassten Gesamtverbrauchspläne zwischen den Agenten der Haushalte kommuniziert. Daraus können durch Methoden

⁷ §31 MsbG

des „Nonintrusive Appliance Load Monitoring“ Rückschlüsse auf die einzelnen Lastvorgänge gezogen werden (vgl. [100]). Darüber hinaus erfolgt dieser Austausch in Echtzeit, so dass z.B. bereits aus der Nichtteilnahme von Haushaltsagenten an den Verhandlungen Rückschlüsse über die Anwesenheit der Verbraucher getroffen werden können. Für individuelles DSM ist diese Fragestellung weniger kritisch, da die Verbrauchsdaten nur lokal zur Optimierung verwendet werden. Auch die Abrechnung der Stromkosten kann lokal erfolgen und durch nachträgliche Stichproben verifiziert werden. In beiden Ansätzen muss der Schutz der lokalen Daten und das DSM-Verfahren selbst vor äußerer Einflussnahme durch entsprechende Sicherheitsmaßnahmen gewährleistet werden.

3.6.5 Flexibilität und weiteres Potenzial

In der vorliegenden Studie wurden zur Vereinfachung ausschließlich verschiebbare Lasten mit festem Lastprofil betrachtet, welche sich innerhalb gewisser zeitlicher Schranken verschieben lassen. Bei der Modellierung der zeitlichen Schranken wurden verschiedene Flexibilitätsgrade evaluiert. Welche davon realistisch sind, muss durch entsprechende Feldversuche ermittelt werden. Dabei sind in dem Modell keine möglichen weiteren Einschränkungen modelliert, welche beispielsweise durch nächtliche Ruhezeiten in Mehrfamilienhäusern auftreten. In diesen dürfen Waschmaschinen und Trockner nur dann betrieben werden, wenn sie ausreichend schallgedämpft sind.

Neben den modellierten verschiebbaren Lasten können auch Kühlgeräte durch DSM-Verfahren reguliert werden. Nach einer Studie der EnergieAgentur in NRW macht der Betrieb von Kühlgeräten wie Kühlschränken und Gefriertruhen durchschnittlich 15% des Gesamtstrombedarfs eines Haushalts aus (vgl. [82]). Es gibt bereits Ansätze, wie die spezifischen Anforderungen für diese Geräte in DSM-Verfahren modelliert werden können [66–70], dabei werden bisher jedoch diverse Vereinfachungen getroffen. Zur realistischen Umsetzung von DSM für Kühlgeräte in Haushalten sind weitere Forschungsarbeiten zur allgemeinen Modellierung solcher Lastverschiebungen notwendig. In dieser Arbeit wurde das Potential aufgezeigt, welches sich durch die technisch relativ leicht umsetzbaren Lastverschiebungen von Geschirrspülmaschinen, Waschmaschinen und Trocknern realisieren lässt. Es ist davon auszugehen, dass das Potential sowie die gesellschaftliche Akzeptanz durch die Weiterentwicklung im Bereich des Internet of Things sich noch weiter steigern werden.

3.7 Zusammenfassung

Es wurden zwei Konzepte zur Umsetzung von DSM in Microgrids vorgestellt. Zum einen ein individuelles DSM, bei welchen die Strombilanzen in jedem Haushalt einzeln optimiert wurden. Zum anderen ein koordinatives DSM, bei welchem die gemeinsame Strombilanz der beteiligten Haushalte durch Verhandlungen in einem Multi-Agenten-System optimiert wurden. Dabei wurden jeweils zwei Zielsetzungen separat untersucht: Die Glättung des lokalen Strombezugs und die Anpassung des Bezugs in Abhängigkeit von zeitvariablen Strompreisen. Dafür wurden geeignete

State-of-the-Art Verfahren ausgewählt, die Modellierung der verschiebbaren Lasten so angepasst, dass innerhalb der Verschiebung das Lastprofil beibehalten wird, und diese für ein Microgrid simuliert. Die angepasste Modellierung ermöglicht eine realistische Betrachtung der möglichen Lastverschiebungen bei Haushaltsgeräten wie Spülmaschinen, Waschmaschinen und Trocknern, welche zu den Hauptlasten gehören, die durch DSM verschoben werden können. Zur Simulation des Microgrids wurden dabei empirisch aufgezeichnete Daten des REFIT Projekts verwendet, bei welchen separate Aufzeichnungen für die möglichen verschiebbaren Lasten vorliegen, und somit realitätsnahe Simulationen durchgeführt. Die Ergebnisse wurden bzgl. ihrer Effekte auf die Strombilanzen des Microgrids, die Spitzenlasten und die CO₂-Emissionen ausgewertet.

Bei der Zielsetzung, den Strombezug zu glätten, empfiehlt sich nach den Ergebnissen der Simulation ein koordinatives Verfahren, da durch die Verhandlungen der Haushaltsagenten im Microgrid bereits bei zeitlich sehr eingeschränkten Lastverschiebungen von einer Stunde eine durchaus bemerkbare Reduktion der Spitzenlasten (von durchschnittlich 8% in den Simulationen) erreicht wurde. Obwohl die Konvergenz des koordinativen Verfahrens in der Theorie allgemein nicht nachgewiesen werden kann, zeigt die Simulation auf realen Lastprofilen, dass es der individuellen Optimierung deutlich überlegen ist. Das Potential von DSM durch individuelles DSM ist deutlich geringer und bedarf hoher zeitlicher Flexibilitäten auf Seiten der Nutzer. Der finanzielle Vorteil, welcher der Energieversorger durch die Anpassung der Lasten erhält, müsste in geeigneter Form an die Endverbraucher weitergegeben werden, um diese zu der Nutzung eines solchen DSM zu motivieren. Mögliche Anreizsysteme wurden in Kapitel 3.6.2 diskutiert.

Bei der Zielsetzung, den Strombezug durch zeitvariable Strompreise zu regulieren, kann die Verschiebung der flexiblen Lasten ohne Berücksichtigung anderer Lasten optimiert werden. Dies führt dazu, dass der individuelle Ansatz zu denselben Ergebnissen wie der koordinative Verbrauch führt, solange keine gemeinsame Solaranlage integriert ist. Da weiterhin keine Unsicherheiten über den anderweitigen Strombedarf berücksichtigt werden müssen, kann die Optimierung sehr zuverlässig erfolgen. Dies macht diesen Ansatz zu einem technisch leicht umsetzbaren Modell. In der Simulation führte das Modell zu einer Reduktion der Stromkosten von bis zu 5%. Unter der Annahme, dass der Emissionsfaktor sich proportional zu den modellierten Strompreisen verhält, wurden die CO₂-Emissionen um bis zu 7% reduziert. Dies zeigt das Potential zur Senkung der CO₂-Emissionen durch DSM-Methoden in der Stromversorgung. Dafür erforderlich sind zeitvariable Strompreise, welche von dem voraussichtlichen Anteil des Stroms durch erneuerbare Energien abhängen.

Kurzfristige Stromlastprognosen für Wohngebäude

Contents

4.1	Ansatz	82
4.2	Literaturreview	83
4.2.1	Bestimmung des Review-Fokus	83
4.2.2	Konzeptualisierung	84
4.2.3	Literatursuche	86
4.2.4	Methodenübersicht	87
4.2.5	Analyse und Synthese	94
4.2.6	Zusammenfassung und Schlussfolgerungen	98
4.3	Experimente	100
4.3.1	Daten	101
4.3.2	Trainings- und Testmengen	106
4.3.3	Methoden	106
4.3.4	Input-Variablen	117
4.3.5	Kennzahlen	119
4.4	Ergebnisse und Auswertung	120
4.4.1	Gesamtübersicht	120
4.4.2	Vergleich der Methoden	120
4.4.3	Skalierungseffekte	125
4.4.4	Prognosezeitraum	127
4.4.5	Analyse der Input-Variablen	129
4.5	Diskussion	132
4.5.1	Limitierungen	133
4.5.2	Weitergehende Forschungsfragen	133
4.6	Zusammenfassung	134

4.1 Ansatz

Zur Optimierung der Energiebilanzen von Microgrids werden kurzfristige Prognosen für den Strombedarf benötigt. In den Kapiteln 2 und 3 wurde dargestellt, wie aufbauend auf Stromlastprognosen die CO₂-Emissionen reduziert, Betriebskosten gespart und zur lokalen Netzstabilität beigetragen werden kann. Im folgenden Kapitel soll nun dargestellt werden, welche Methoden zur Prognose des Strombedarfs verwendet werden können, mit welcher Prognosegenauigkeit zu rechnen ist und welche Schlussfolgerungen daraus für die Anwendungen gezogen werden können.

Kurzfristigen Stromlastprognosen (engl. Short-Term Load Forecasting – kurz: STLF) finden seit den 80er Jahren Anwendung in der Energiewirtschaft. Auf Basis von Prognosen über die anfallenden Lasten in einem Bilanzkreis werden u.a. die Einsatzfahrpläne von Kraftwerken erstellt [101]. Zur Erstellung der Prognosen sind historische Daten über den Lastgang notwendig, welche für Bilanzkreise sowie Verbraucher mit einem Jahresverbrauch von mehr als 100 MWh Strom viertelstündlich aufgezeichnet werden. Dagegen sind in Haushalten i.d.R. Stromzähler installiert, welche den Lastgang nicht aufzeichnen. Zur Prognose dieser Lastgänge werden stattdessen Standardlastprofile verwendet.

Durch die Digitalisierung der Energienetze ergeben sich neue Möglichkeiten. Mit der Installation von Smart Metern können die Stromverbrauchsdaten auch in Haushalten in engen Zeitintervallen erfasst sowie digital und nahezu in Echtzeit an den Energieversorger oder ein lokales Energiemanagementsystem übermittelt werden. Um diese Daten zur Erstellung von kurzfristigen Stromlastprognosen auf Haushaltsebene und somit zur Optimierung von Energienetzen zu nutzen, müssen entsprechende Verfahren entwickelt und evaluiert werden. Methoden, die bereits zur Prognose des Energieverbrauchs für Bilanzkreise verwendet werden, können als Basis dienen. Die Varianz der Lastgänge auf Haushaltsebene ist relativ gesehen jedoch wesentlich höher. Zudem heben sich spezifische Verhaltensmuster einzelner Nutzer bei der Prognose von Stromlasten für Bilanzkreise bis zu einem gewissen Grad auf, während sie bei den Stromlastprognosen einzelner Haushalte oder Wohnblöcke stark ins Gewicht fallen. Daher müssen die vorhandenen Verfahren angepasst, erprobt und ggf. weiterentwickelt werden. Es bietet sich darüber hinaus an, neuere Verfahren aus dem Bereich der künstlichen Intelligenz und des maschinellen Lernens zur Prognose der kurzfristigen Stromlasten zu evaluieren.

Dazu wird im folgenden Abschnitt zunächst ein umfangreicher Literaturreview¹ nach der Methode von J. vom Brocke [3] präsentiert, der darstellt, welche Methoden für kurzfristige Stromlastprognosen für einzelne Haushalte, Wohnblöcke und Microgrids in der aktuellen Forschungslandschaft diskutiert, welche Input-Variablen hierfür verwendet, welche Ergebnisse damit erzielt werden und in welchem Maße die evaluierten Ergebnisse vergleichbar sind.

Aufbauend auf dieser Studie werden die vielversprechendsten Methoden imple-

¹ Dieser wurde auf der International KES Conference on Intelligent Decision Technologies 2015 vorgestellt und in den Proceedings veröffentlicht. Wesentliche Inhalte entsprechen daher der Darstellung in [51].

mentiert und in einer Analyse auf drei öffentlich verfügbaren Datensätzen getestet². Dass der Vergleich auf *öffentlich* verfügbaren Datensätzen erfolgt, ist von wesentlicher Bedeutung, da in der Literaturrecherche deutlich wird, dass die Prognosegenauigkeit stark von der zugrundeliegenden Datenreihe abhängt und sich die Ergebnisse einer Evaluation daher nur eingeschränkt vergleichen lassen, wenn die Auswertung auf projekt-internen Datensätzen erfolgt. In der Analyse werden unterschiedliche Aggregationsstufen der Verbrauchsdaten betrachtet. Insgesamt werden die Prognosen für 165 Datenreihen erprobt. Neben dieser Evaluation, welche als Benchmarking für weitere Methoden verwendet werden kann, wird untersucht, wie sich der Prognosefehler mit zunehmendem Prognosehorizont und mit zunehmendem Aggregationsniveau entwickelt. Dabei wird u.a. ein Zusammenhang zwischen dem Variationskoeffizienten einer Datenreihe und der Prognosegenauigkeit aufgezeigt. Die Ergebnisse der Analysen werden in Hinblick auf ihre Verwendung im Microgrid diskutiert.

4.2 Literaturreview

Um zunächst eine Übersicht der Forschungsansätze und die bisher erzielten Ergebnisse zu erhalten, wird eine umfassende und systematische Literaturrecherche nach dem Konzept von J. vom Brocke [3] vorgenommen. Dazu wird die Literaturrecherche in fünf Phasen eingeteilt: (1) Die Bestimmung des Review-Fokus, (2) die Konzeptualisierung des Themas, (3) die eigentliche Literatursuche, (4) die Analyse und Synthese der gefundenen Literatur und (5) die Schlussfolgerungen aus dem Review. Die Gliederung dieses Reviews orientiert sich an diesen Phasen, wobei ein zusätzlicher Abschnitt zur Vorstellung der meistverwendeten Methoden eingefügt wird, um so einen Einblick in die grundlegenden Prinzipien der Verfahren und die damit verbundenen Vor- und Nachteile zu geben.

4.2.1 Bestimmung des Review-Fokus

Stromlastprognosen werden bereits seit den 80er Jahren untersucht, da sie sowohl bei der Planung als auch bei dem Betrieb von Energiesystemen zum Einsatz kommen (vgl. [101]). Dabei unterscheidet man zwischen lang-, mittel- und kurzfristigen Stromlastprognosen. Eine Übersicht der in diesem Kontext verwendeten Verfahren kann in [103] und [104] gefunden werden. Als kurzfristige Prognosen werden diejenigen bezeichnet, deren Prognosezeitraum kürzer als ein Tag ist. Die Stromlasten werden dabei üblicherweise für Zeitintervalle in der Größenordnung von 15 Minuten oder einer Stunde prognostiziert.

Für die Erstellung von kurzfristigen Stromlastprognosen in Smart Grids und Microgrids sind diverse Verfahren vorgeschlagen und analysiert worden. Dazu gehören statistische Zeitreihenverfahren, künstliche neuronale Netze, Clustering Verfahren und einige weitere. Neben den autokorrelierten Werten der Zeitreihen werden teilweise exogene Variablen wie Wetterdaten in der Prognose berücksichtigt. Leider sind

² Ein Teil dieser Analysen wurden auf der Smart-GIFT 2016 vorgestellt und in den Proceedings der Konferenz [102] veröffentlicht.

die meisten Verfahren auf Datensätzen evaluiert, die nicht öffentlich einsehbar sind. Dies ist bedauerlich, weil sich die erzielten Ergebnisse somit schlecht einordnen lassen, da die Genauigkeit sehr stark von dem zugrundeliegenden Datensatz abhängt und ohne die Veröffentlichung des Datensatz die Ergebnisse nur unzureichend mit denen anderer Methoden verglichen werden können.

In dem Literaturreview soll nun zum einen ein Überblick über die verwendeten Methoden gegeben und zum anderen analysiert werden, inwiefern die Ergebnisse vergleichbar sind und welche Schlussfolgerungen für die weitere Forschung von STLF abgeleitet werden können. Die leitenden Fragen des Reviews sind die Folgenden:

1. Welche Methoden kommen zur Anwendung?
2. Welche Prognosegenauigkeiten werden für welche Datensätzen erreicht?
3. Welche Auswirkungen haben die exogene Variablen?
4. Welche Datensätze sind zur Evaluation von STLF öffentlich verfügbar?

4.2.2 Konzeptualisierung

Für die Evaluation wird nach dem Ansatz von Webster und Watson [WW02] eine Konzeptmatrix entwickelt, welche als Ordnungsrahmen für den Literaturreview dient. Anhand dieser werden die Artikel des Reviews gemäß ihrer unterschiedlichen Konzepte geordnet, um so eine reine Auflistung der existierenden Literatur zu vermeiden und die vorgestellten Ansätze leichter vergleichen zu können.

Aus den aufgestellten Forschungsfragen werden drei Dimensionen für eine Konzeptmatrix abgeleitet. Die erste Dimension ist die *Methode*, die zur Prognose verwendet wird, eine zweite Dimension ist die *Anzahl der Haushalte*, für welche der Stromverbrauch prognostiziert wird. Weiterhin soll untersucht werden, wie die Methoden im Vergleich zueinander abschneiden, daher wird notiert, ob in dem Artikel selbst eine vergleichende Evaluation durchgeführt wird und ob der verwendete Datensatz öffentlich verfügbar ist. Weiterhin wird festgehalten, ob exogene Variablen als Input-Variablen verwendet werden. Diese drei zusätzlichen Fragen werden in einer dritten Dimension *Vergleichbarkeit* notiert. Die Dimensionen der Konzeptmatrix sind Abb. 4.1 dargestellt.

4.2.2.1 Methoden

Zur Klassifizierung der Methoden wurde zunächst zwischen zwei Kategorien unterschieden: statistischen Zeitreihenverfahren und Methoden aus dem Bereich der künstlichen Intelligenz. Nach einer ersten Sichtung der Artikel wurde die Aufteilung verfeinert und die Dimension in acht Kategorien unterteilt: lineare Regressionsverfahren, AR(I)MA-Modelle, exponentielle Glättung, Zustandsraummodellierung mit Kalmanfiltern, neuronale Netze, Support Vektor Regression, Clustering sowie eine weitere Kategorie für alle verbleibenden Methoden. Die Grundlagen der verschiedenen Ansätze werden im Abschnitt 4.2.4 vorgestellt.

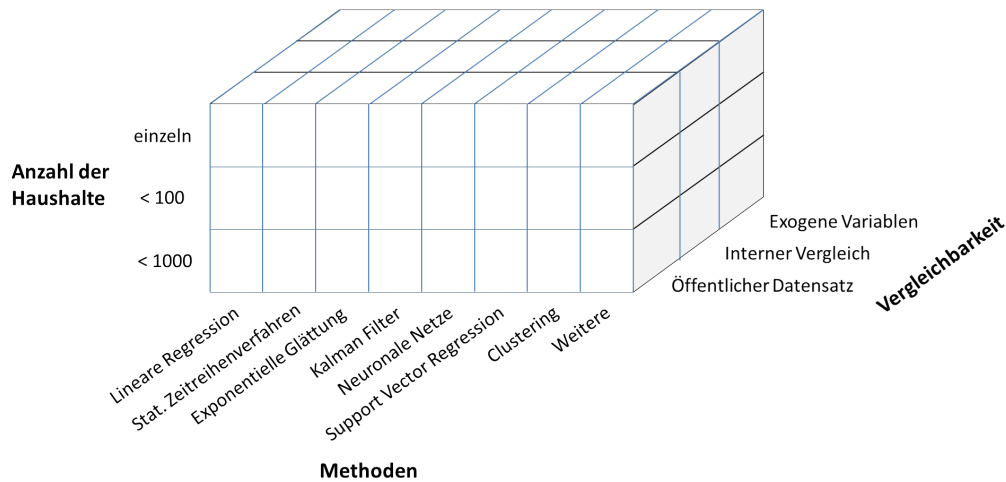


Abbildung 4.1: Dimensionen der Konzeptmatrix zur Gliederung der Literaturreviews

4.2.2.2 Anzahl der Haushalte

Um die Ergebnisse der verschiedenen Artikel zu vergleichen, wird zwischen der Anzahl der Haushalte unterschieden, für welche der Strombedarf prognostiziert werden soll. Die Stromlastkurven einzelner Haushalte unterscheiden sich von Tag zu Tag sehr stark, während die Lastkurven von mehreren aggregierten Haushalten mit einer zunehmenden Anzahl von Haushalten gleichmäßiger werden: Die Standardabweichung der Stromlast zu einer bestimmten Tageszeit nimmt gegenüber dem Durchschnittswert dieser Tageszeit ab.

Diese Aussage beruht auf empirischen Beobachtungen und lässt sich theoretisch stützen: Nimmt man an, die Stromlasten von unterschiedlichen Haushalten für ein Zeitintervall des Tages sind unabhängig und identisch mit dem Erwartungswert μ und der Varianz σ^2 verteilt, dann ist die Erwartung der Summe über n Haushalte $n\mu$ und die Varianz mit $n\sigma^2$. Die Standardabweichung $\sqrt{n}\sigma$ der Summe nimmt somit bei steigendem n im Verhältnis zum Erwartungswert ab.

In dem Literaturreview wird daher zwischen Prognosen für (1) einzelne Haushalte, (2) für Wohnblöcke mit weniger als 100 Wohnungen und (3) für Wohnsiedlungen mit weniger als 1000 Haushalten unterschieden. Kurzfristige Stromlastprognosen für mehr als 1000 Haushalte sind außerhalb des Review-Fokus, der explizit Methoden für den Bedarf einzelner Haushalte und Microgrids mit entsprechend hoher Variabilität darstellen möchte.

4.2.2.3 Vergleichbarkeit

Der Strombedarf kann mit externen Zuständen wie dem Wetter (Temperatur, Sonneneinstrahlung, Feuchtigkeit, etc.) oder mit externen Ereignissen wie beispielsweise den Schulferien korreliert sein. Solche Daten können als sogenannte exogene Variablen in das Modell der kurzfristigen Stromprognosen aufgenommen werden. Dabei

besteht die Gefahr, dass die Korrelation sehr schwach ist und bei einer unzureichenden Datengrundlage eine Überanpassung an die Trainingsdaten stattfindet. In dem Review soll erfasst werden, ob exogene Variablen in den Modellen dazu beitragen, die Prognosegenauigkeit zu verbessern. Daher wird notiert, welche Artikel exogene Variablen in der Berechnung verwenden. Zudem wird notiert, ob die Evaluation eines Artikels mehrere Ansätze vergleicht, so dass ein direkter Vergleich auf demselben Datensatz verfügbar ist. Ist der Datensatz öffentlich verfügbar, wird dies ebenfalls festgehalten, da somit die Ergebnisse des Artikels mit denen anderer Artikel auf dem gleichen Datensatz verglichen werden können.

Die Konzeptmatrix hat somit drei Einträge hinsichtlich der Vergleichbarkeit. Es wird festgehalten, ob exogene Variablen in das Modell eingehen, ob der Ansatz innerhalb des Artikels mit anderen verglichen wird und ob der zugrunde liegende Datensatz öffentlich verfügbar ist.

4.2.3 Literatursuche

4.2.3.1 Suchstring

Die Suche erfolgte in der englischen Sprache, da die entsprechenden Analysen meist auf englischsprachigen Konferenzen vorgestellt und in englischsprachigen Journals veröffentlicht werden. Als naheliegender Suchbegriff bot sich „short term load forecasting“ an. Da einige Artikel den Begriff „short term forecasting“ ohne den Term „load“ verwenden, wurden die Begriffe separat in den Suchstring aufgenommen. Der Fokus der Recherche sind Stromlastprognosen für einzelne Haushalte und Microgrids, daher wurde zudem der Term „residential“ zu dem Suchstring hinzugefügt. Der finale Suchstring verband diese drei Terme mit Konnektoren:

“short term forecasting” AND “load” AND “residential”

4.2.3.2 Datenbanken

Als Datenbanken für die Literaturrecherche wurden die IEEE xplora Digital Library³ und Google scholar⁴ gewählt. Google Scholar bietet sich für Literaturrecherchen an, da die meisten Peer-Review-Artikel und Bücher sowie Konferenzbeiträge und viele Dissertationen heutzutage auf Google Scholar angezeigt werden. Die zusätzliche Suche auf IEEE xplora wurde durchgeführt, da diese Datenbank speziell zu Computerwissenschaften und Elektrotechnik viele interessante Beiträge bietet. Der Suchzeitraum wurde begrenzt auf den Zeitraum von 2010 bis 2015, da Smart Meter erst seit ca. 2010 auf Haushaltsebene Verwendung finden.

Die beschriebene Stichwortsuche führte zu 367 Artikeln in Google Scholar und zu 82 Artikel in IEEE xplora. Dabei wurden fast alle wissenschaftlichen Beiträge, die auf IEEE xplora gefunden wurden, auch durch Google Scholar gesichtet. Aus-

³ <http://ieeexplore.ieee.org/>

⁴ <https://scholar.google.de/>

geführt wurde die Stichwortsuche auf Google Scholar zwischen dem 27. und 29. Dezember 2014 und zwischen dem 7. und 10. Januar 2015 auf IEEE xplora.

4.2.3.3 Auswertungsmethode

Die 375 gefundenen Artikel wurden schrittweise anhand des Titels, des Abstracts und schließlich anhand des vollständigen Artikels analysiert. Zunächst wurden 166 Artikel aussortiert, deren Titel eindeutig auf ein anderes Forschungsthema schließen ließ. Aus den verbleibenden Artikeln wurde aufgrund des Abstracts diejenigen ausgewählt, die sich tatsächlich mit kurzfristigen Lastprognosen beschäftigen. Diese 50 Artikel wurden vollständig gelesen und analysiert. Dabei wurden nochmals einige ausgeschlossen. Die verbleibenden 18 Artikel wurden anhand der Konzeptmatrix eingeordnet und in die hier vorliegende Literaturrecherche aufgenommen.

4.2.4 Methodenübersicht

Die in der Konzeptualisierung genannten Methoden sind mehrfach als Ansatz für STLTF gewählt worden, daher soll im Folgenden ein kurzer Überblick über diese Verfahren gegeben werden, welcher die zugrundeliegenden Prinzipien erläutert und so einen Einblick in die jeweiligen Vor- und Nachteile gibt.

4.2.4.1 Lineare Regression

Die Methodik der Regressionsanalyse wird angewandt, um die statistische Abhängigkeit einer Variablen y von k weiteren Variablen, sogenannten Regressoren x_1, \dots, x_k , mittels einer geeigneten Funktion $f(x_1, \dots, x_k)$ abzuschätzen. In der linearen Regression (LR) wird angenommen, dass sich die Variable y als Linearkombination der Variablen x_1, \dots, x_k darstellen lässt, welche als Regressoren bezeichnet werden: Sei $y \in \mathbb{R}$ und $\mathbf{x} = (x_1, \dots, x_k) \in \mathbb{R}^k$, dann wird y wie folgt modelliert:

$$y = f(\mathbf{x}) + \varepsilon := a_0 + \mathbf{a}^T \mathbf{x} + \varepsilon, \quad (4.1)$$

wobei $a_0 \in \mathbb{R}$ und der Vektor $\mathbf{a} \in \mathbb{R}^k$ die Regressionskoeffizienten der Linearkombination beschreiben; $\varepsilon \in \mathbb{R}$ beschreibt den Fehler der linearen Abschätzung $f(\mathbf{x})$. Gegeben sind üblicherweise n Messwerte $(y_1, \mathbf{x}_1), \dots, (y_n, \mathbf{x}_n)$ mit $y_i \in \mathbb{R}, \mathbf{x}_i \in \mathbb{R}^k$ für alle $i = 1, \dots, n$. Aus diesen werden die Regressionskoeffizienten a_0 und \mathbf{a} so bestimmt, dass die Fehlerterme $\varepsilon_1, \dots, \varepsilon_n$ möglichst klein werden. Ein typisches Verfahren ist die Methode der kleinsten Quadrate, bei welcher die Summe der quadrierten Fehlerterme minimiert wird.

Zur Abschätzung von zukünftigen Werten einer Zeitreihe können sowohl durch zurückliegende Werte der Zeitreihe als auch durch exogene Variablen als Regressoren x_1, \dots, x_k gewählt werden.

Es handelt es sich um ein vergleichsweise einfaches Modell, welches sich leicht implementieren lässt. Eine Herausforderung liegt in der Auswahl geeigneter Regressoren. Werden unkorrelierte Variablen oder zu viele Variablen gewählt, besteht

die Gefahr der Überanpassung, dem sogenannten *Overfitting*. In diesem Fall kann es sein, dass Zusammenhänge modelliert werden, die nicht verallgemeinert werden können und eine Übertragung auf unbekannte Messdaten zu entsprechend großen Fehlertermen führt. Im schlimmsten Fall entspricht oder übertrifft die Anzahl der Regressionskoeffizienten die Anzahl an Datenpaaren und es wird überhaupt keine Abschätzung vorgenommen, sondern die y -Werte der Messdaten in den Regressionskoeffizienten gespeichert. Liegt eine Überanpassung vor, kann dies durch geeignete Tests wie eine Kreuzvalidierung aufgezeigt werden. Es ist vorteilhaft, direkt bei der Erstellung des Modells die Anzahl der Variablen in dem Modell niedrig zu wählen, um eine Überanpassung zu vermeiden. Dies gilt auch für die folgenden Regressionsmodelle.

Lineare Regression ist dem Namen entsprechend ein lineares Modell, welches dementsprechend auch nur lineare Zusammenhänge darstellen kann.

4.2.4.2 AR(I)MA-Modelle

In der statistischen Zeitreihenanalyse wird eine Zeitreihe mit äquidistanten Zeitabständen als stochastischer Prozess in diskreter Zeit interpretiert, d.h. als Familie $X = (X_t : t \in T)$ von reell- oder komplexwertigen Zufallsvariablen X_t auf einem Wahrscheinlichkeitsraum indiziert mit der Zeit $t \in T$ (vgl. [105]).

Um von einer Realisation der Zeitreihe X oder vielmehr einem Ausschnitt X_1, X_2, \dots, X_n statische Rückschlüsse auf das zukünftige Verhalten der Zeitreihe zu ermöglichen, werden zunächst Charakteristika der Zeitreihe untersucht, welche eine Übertragung auf die Zukunft möglich machen. Kann man davon ausgehen, dass eine Zeitreihe (schwach) stationär ist, das heißt, dass der Erwartungswert konstant, die Varianz endlich und die Autokovarianz stabil gegenüber Verschiebungen ist, dann lassen sich Abhängigkeiten der beobachteten Werte auf zukünftige Werte der Zeitreihe übertragen. Drei typische lineare Zeitreihenverfahren zur Modellierung dieser Abhängigkeiten sind *autoregressive* (AR) Modelle, und *Moving Average* (MA) Modelle sowie die Kombination der beiden Modelle, sogenannte *ARMA-Modelle*.

In ein ARMA(p, q)-Modell gehen die p autoregressive Zeitreihenwerte und ein gleitender Durchschnitt (moving average) von q Rauschtermen ε_t in die Modellierung der Zeitreihe ein, $p, q \in \mathbb{N}$. Die Zeitreihe X wird wie folgt modelliert:

$$X_t = \sum_{k=1}^p a_k X_{t-k} + \sum_{l=1}^q b_l \varepsilon_{t-l} + \varepsilon_t,$$

dabei bezeichnen a_1, \dots, a_p und b_1, \dots, b_q die Koeffizienten der Modellierung, wobei $a_p \neq 0$ und $b_q \neq 0$. Der Prozess $\varepsilon = (\varepsilon_t : t \in T)$ beschreibt ein *weißes Rauschen*, d. h. einen stochastischen Prozess von unkorrelierten Zufallsvariablen mit $\mathbb{E}[\varepsilon_t] = 0$ und $\text{Var}[\varepsilon_t] \in (0, \infty)$ für alle $t \in T$.

Ist die Zeitreihe selbst nicht stationär, aber die Folge der d -ten Differenzen $Y = (Y_t = X_t - X_{t-d} : t \in T)$, wird das Zeitreihenmodell von Y untersucht, um Aussagen über X zu treffen. Dieses Modell wird als integriertes ARMA-Modell (*ARIMA*) der

Ordnung (p,d,q) bezeichnet.

Letztlich handelt es sich bei diesen Zeitreihenverfahren um spezielle Regressionsmodelle, bei welchen die Abweichungen als stochastische Prozesse modelliert werden. Für die Prognose von zukünftigen Elementen der Zeitreihe müssen ebenfalls die Regressionskoeffizienten ermittelt werden. Auch für diese Verfahren besteht die Gefahr der Überanpassung. Daher ist nach der Box-Jenkins-Methode zunächst eine Modellidentifikation, -schätzung und -validierung vor der Anwendung vorgesehen (vgl. [106]). Weiterhin handelt es sich um ein lineares Modell, welches lineare Zusammenhänge darstellt.

4.2.4.3 Exponentielle Glättung

Exponentielle Glättung (*ES*) ist ebenfalls ein Modell der statistischen Zeitreihenanalyse. Es wird hier gesondert behandelt, da es teilweise als heuristisches Verfahren ohne explizit formuliertes Zeitreihenmodell verwendet oder den Zustandsraummodellen zugeordnet wird (vgl. [107]).

Es wird die Darstellung gemäß der statistischen Zeitreihenanalyse betrachtet (vgl. [105]): Lässt sich eine Zeitreihe $X = (X_t : t \in \mathbb{N})$ wie folgt modellieren:

$$X_t = X_{t-1} + \varepsilon_t + (\alpha - 1)\varepsilon_{t-1}, \quad t \geq 1, \quad X_0 = e_0,$$

wobei $\alpha \in (0, 1)$ und $\varepsilon_t, t \in \mathbb{N}$ stochastisch unabhängige, reelle, zentrierte, quadratintegrale Zufallsvariablen seien, dann gilt für die Vorhersage von X_{t+1} mit dem bedingten Erwartungswert $\hat{X}_{t+1} = \mathbb{E}[X_{t+1} | \mathcal{B}_t]$ mit $\mathcal{B}_t = \sigma(X_u, u \leq t)$:

$$\hat{X}_{t+1} = \alpha X_t + (1 - \alpha)\hat{X}_t, \tag{4.2}$$

$$= \alpha \sum_{k=0}^t (1 - \alpha)^k X_{t-k}. \tag{4.3}$$

Die Anwendung dieser Gleichungen zur Prognose wird als exponentielle Glättung erster Ordnung bezeichnet. Die Gleichungen (4.2) und (4.3) betonen verschiedene Aspekte des Verfahrens: In der rekursiven Formulierung wird der errechnete Prognosewert des Vorgängers mit dem tatsächlichen Wert abgeglichen und die entstandene Abweichung in der Prognose des nächsten Wertes berücksichtigt. Dass dabei alle vergangenen Werte der Zeitreihe in die Schätzung zukünftiger Werte eingehen, wird in der zweiten Gleichung deutlich. Die Werte der Zeitreihe werden gemäß ihrer Aktualität gewichtet. Das Gewicht der vergangenen Zeitreihenwerte nimmt ab, je weiter die Werte in der Vergangenheit liegen.

Vorteile des Verfahrens liegen darin, dass die Methode leicht verständlich ist und schnell berechnet werden kann. Zudem müssen die Daten nicht lange vorgehalten werden. Die Einfachheit ist allerdings auch ein Nachteil des Verfahrens. Der einzige Modifikationsfaktor ist α , wodurch das Modell vielen Zeitreihen nicht gerecht wird. Zudem führen Zufallsschwankungen in der Zeitreihe zu großen Fehlern in der Prognose der darauffolgenden Werte.

4.2.4.4 Zustandsraummodellierung mit Kalman Filtern

Zustandsraummodelle beschreiben dynamische Systeme, bei welchen die Zustände einer Zeitreihe X , die nicht direkt beobachtbar ist, mit den Zuständen einer anderen beobachtbaren Zeitreihe Y verknüpft werden. Mittels Kalman Filter (KF) können auch bei Vorliegen fehlerbehafteter Beobachtungen Rückschlüsse auf die Zustände der nicht beobachtbaren Zeitreihe berechnet werden. Die folgende Beschreibung eines Zustandsraummodells folgt der Definition und Notation aus [105].

Es werden zwei diskrete, mehrdimensionale, stochastische Prozesse $X = (X_t : t \in \mathbb{N})$ und $Y = (Y_t : t \in \mathbb{N})$ mit $X_t \in \mathbb{R}^r$ und $Y_t \in \mathbb{R}^v$ modelliert. Dabei seien die Werte des Prozesses Y beobachtbar. Es wird angenommen, dass X eine Markovkette ist, d.h. dass der Zustand X_{t+1} nur von dem Vorgänger X_t abhängt:

$$X_{t+1} = F_t X_t + \varepsilon_t, \quad (4.4)$$

wobei die Übergangsmatrix $F_t \in \mathbb{R}^{r \times r}$ bekannt ist und $\varepsilon_t \in \mathbb{R}^r$ eine zufällige Störung beschreibt. Für die Zustände der beobachtbaren Zeitreihe Y_t sollen folgende Beobachtungsgleichungen gelten:

$$Y_t = G_t X_t + \eta_t, \quad (4.5)$$

wobei $G_t \in \mathbb{R}^{v \times r}$ die Verknüpfung der beiden Zeitreihen und $\eta_t \in \mathbb{R}^v$ eine zufällige Störung beschreibt. Die Matrix G_t sei ebenfalls bekannt. Für die beiden Störungsvektoren ε_t, η_t gelte jeweils für alle t , dass der Erwartungswert komponentenweise 0 sei, d.h. $\mathbb{E}[\varepsilon_t] = \mathbf{0} \in \mathbb{R}^r$ und $\mathbb{E}[\eta_t] = \mathbf{0} \in \mathbb{R}^v$. Die Kovarianzen der Störungsvektoren seien gegeben durch

$$\mathbb{E}[\varepsilon_s \varepsilon_t^T] = \begin{cases} Q_t, & \text{falls } s = t, \\ \mathbf{0} \in \mathbb{R}^{r \times r}, & \text{sonst.} \end{cases} \quad (4.6)$$

$$\mathbb{E}[\eta_s \eta_t^T] = \begin{cases} R_t, & \text{falls } s = t, \\ \mathbf{0} \in \mathbb{R}^{v \times v}, & \text{sonst.} \end{cases} \quad (4.7)$$

Dabei seien die Matrizen $Q_t \in \mathbb{R}^{r \times r}$ und $R_t \in \mathbb{R}^{v \times v}$ für alle t bekannt. Zudem seien die Komponenten der Störvektoren $\varepsilon_0, \varepsilon_1 \dots$ und $\eta_0, \eta_1 \dots$ paarweise unkorreliert, d.h. $\mathbb{E}[\varepsilon_s \eta_t^T] = \mathbf{0} \in \mathbb{R}^{r \times v} \forall s, t \geq 0$. Weiterhin sei der Anfangszustand X_0 mit den Störungen $\{\varepsilon_t\}$ und $\{\eta_t\}$ im selben Sinne unkorreliert.

Kalman Filter beschreiben eine Methode, mit welcher für ein solches Zustandsraummodell der Wert X_{t+1} aus den Beobachtungen Y_0, \dots, Y_t mithilfe der Übergangsmatrizen F_t, G_t und Kovarianzmatrizen Q_t und R_t prognostiziert wird, so dass die Varianz des Prognosefehlers minimiert wird. Rekursiv können h -Schrittprognosen für $h > 1$ berechnet werden.

Kalman Filter werden oft dann verwendet, wenn ein Prozess nur mit Fehlern gemessen werden kann. Ein typischer Anwendungsfall sind beispielsweise Trackingverfahren, bei welchen in Echtzeit aus verrauschten Radardaten möglichst zuverlässig

sig und schnell verlässliche Informationen zu Position und Geschwindigkeit von sich bewegenden Objekten gewonnen werden sollen.

4.2.4.5 Künstliche neuronale Netze

Künstliche neuronale Netze (engl. artificial neuronal networks – abgekürzt *ANN*) sind ein nichtlineares Regressionsmodell, welches sich im Aufbau und der Konzeption an der Funktionsweise des menschlichen Gehirns orientiert. Dazu werden Schichten von Neuronen modelliert, welche die Informationsverarbeitung im Gehirn nachbilden. Jedes Modell besteht aus mindestens zwei Schichten von künstlichen Neuronen, einer Eingabeschicht und einer Ausgabeschicht. Dazwischen werden optional je nach Modell eine bis mehrere „verborgene“ Schichten von künstlichen Neuronen modelliert. Der Informationsfluss in einem solchen Netzwerk wird in der Regel ausgehend von der Eingabeschicht über die verborgene(n) Schicht(en) zur Ausgabeschicht modelliert. In Abb. 4.2 ist ein ANN mit drei Schichten dargestellt; der Informationsfluss entspricht den Kanten, welche die Neuronen verbinden. Die Stärke einer solcher Verbindung wird mit einem Gewicht ausgedrückt.




Abbildung 4.2: Modell für ein künstliches neuronales Netz mit einer Ausgabeschicht, einer verborgenen Schicht und einer Ausgabeschicht.

Die Neuronen nehmen dabei abhängig von dem sie erreichenden Input einen aktiven oder einen inaktiven Zustand an. In einem aktiven Zustand geben sie einen Impuls weiter, in einem inaktiven keinen oder nur einen sehr schwachen. Zur Berechnung des Aktivierungszustandes wird eine nichtlineare sogenannte Aktivierungsfunktion verwendet, welche Ausgabewerte im Intervall $[0, 1]$ oder $[-1, 1]$ annimmt. Eine Standardwahl für die Aktivierungsfunktion sind aufgrund ihrer Differenzierbarkeit Sigmoidfunktionen. Der Input berechnet sich aus dem Aktivierungszustand der vorausgehenden Neuronen und der Stärke der Verbindungen. In der Trainingsphase des Modells werden die Gewichte der Verbindungen bestimmt, bzw. erlernt. Ein Standardverfahren zur Bestimmung der Gewichte ist die sogenannte *Backpropagation*: Durch ein Gradientenverfahren wird versucht, den quadratische Fehler des

modellierten Ausgabewertes zu dem echten Ausgabewert zu minimieren.

Ein außerordentlicher Vorteil von neuronalen Netzen liegt darin, dass nichtlineare Zusammenhänge dargestellt werden können. Ein typisches Beispiel ist das XOR-Problem. Es kann durch ein künstliches neuronales Netz mit zwei Input-Neuronen, zwei Neuronen in der verdeckten Schicht und einem Output-Neuron gelernt werden. Nach dem Universellen Approximationstheorem von Cybenko [108] kann jede Funktion mit einem neuronalen Netz mit endlich vielen Neuronen, einer verdeckten Schicht und sigmoiden Aktivierungsfunktionen mit beliebiger Genauigkeit approximiert werden. Ein wesentlicher Nachteil liegt darin, dass der Lernprozess zur Bestimmung der Gewichte sehr langsam ist. Wie bei den bisher genannten Verfahren besteht auch bei neuronalen Netzen die Gefahr der Überanpassung, wenn zu viele verdeckte Neuronen modelliert werden.

4.2.4.6 Support Vector Regression

Support Vector Regression (SVR) bezeichnet ein Regressionsverfahren, welches sich von dem Klassifikationsverfahren Support Vector Machines (SVM) ableitet. Bei SVM wird für eine Menge von Trainingsdaten $(y_1, \mathbf{x}_1), \dots, (y_n, \mathbf{x}_n)$ mit $\mathbf{x}_i \in \mathbb{R}^k$ und $y_i \in \{-1, 1\}$ eine Hyperebene in \mathbb{R}^k konstruiert, für welche sich alle \mathbf{x} -Werte mit positiven y -Werten auf einer Seite und alle \mathbf{x} -Werte mit negativen y -Werten auf der anderen Seite befinden, so dass der kleinste Abstand eines x -Wertes zur Hyperebene maximal wird (vgl. Abb. 4.3).

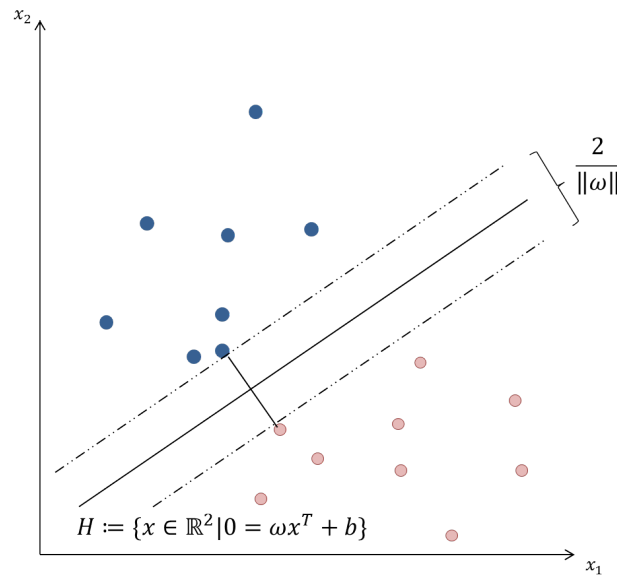


Abbildung 4.3: Modellierung einer Hyperebene in \mathbb{R}^2 , welche die zwei Klassen unterschiedlich eingefärbter Punkte in \mathbb{R}^2 trennt, so dass der kleinste Abstand zu einem der Punkte maximal wird. Der Abstand zwischen der Hyperebene und einem Punkt \mathbf{x} beträgt gemäß des Optimierungsproblems mindestens $1/\|\omega\|$.

Eine Hyperebene H in \mathbb{R}^k lässt sich durch einen Normalenvektor $\omega \in \mathbb{R}^k$ und

einen Stützvektor $\mathbf{b} \in \mathbb{R}^k$ beschreiben: $H := \{\mathbf{x} \in \mathbb{R}^k | \langle \mathbf{x}; \boldsymbol{\omega} \rangle + \mathbf{b} = 0\}$, wobei $\langle \cdot; \cdot \rangle$ das Skalarprodukt im euklidischen Raum bezeichne. Es wird diejenige Hyperebene gesucht, für welche der kleinste Abstand zu einem \mathbf{x} -Wert der Trainingsmenge maximal wird und welche die Trainingsdaten gemäß ihrer y -Werte trennt. Diese Anforderung ist äquivalent zur Minimierung von $\|\boldsymbol{\omega}\|^2$ unter der Nebenbedingung dass $y_i(\langle \mathbf{x}_i; \boldsymbol{\omega} \rangle + \mathbf{b}) \geq 1 \forall i \in \{1, \dots, n\}$ (vgl. [109]). Ein \mathbf{x} -Wert mit unbekanntem y -Wert wird mittels seiner Position zur Hyperebene klassifiziert:

$$f(\mathbf{x}) = \text{sgn}(\langle \mathbf{x}; \boldsymbol{\omega} \rangle + \mathbf{b}), \quad (4.8)$$

dabei bezeichne sgn die Vorzeichenfunktion. Die Minimierung von $\|\boldsymbol{\omega}\|^2$ kann durch Standardverfahren der quadratischen Optimierung gelöst werden. Die Komplexität hängt dabei von der Dimension k der Trainingsdaten ab. Wird alternativ das duale Problem gelöst, hängt die Komplexität von der Anzahl n der Trainingsdaten ab.

Das beschriebene Verfahren legt ein lineares Klassifikationsproblem zugrunde, welches auf viele Fälle nicht zutrifft. Daher wird bei SVM oft der sogenannte Kernel-Trick verwendet, bei welchem die Daten in einen höherdimensionalen Raum projiziert werden, in welchem dann nach einer geeigneten Hyperebene gesucht wird. Dieses Verfahren lässt sich effizient lösen, wenn das Skalarprodukt der projizierten x -Werte durch eine geeignete Kernfunktion ersetzt wird (vgl. [110]). Die duale Form des Optimierungsproblems hängt weiterhin von der Dimension n ab. Die effiziente Lösung von in \mathbb{R}^k nicht-linearen Klassifikationsproblemen ist ein wesentlicher Vorteil der SVM.

Übertragen auf ein Regressionsverfahren zur Bestimmung von y soll eine Hyperebene $H = \{\mathbf{x} \in \mathbb{R}^k | \langle \mathbf{x}; \boldsymbol{\omega} \rangle + \mathbf{b} = 0\}$ bestimmt werden, für welche der y -Wert eines \mathbf{x} -Wertes durch seine Position zur Hyperebene mittels der Funktion

$$f(\mathbf{x}) = \langle \mathbf{x}; \boldsymbol{\omega} \rangle + \mathbf{b} \quad (4.9)$$

approximiert wird. Dabei werden Abweichungen, welche kleiner als ein festgelegtes $\varepsilon \in \mathbb{R}$ sind, akzeptiert. Es wird wie bei SVM diejenige Hyperebene gesucht, für welche $\|\boldsymbol{\omega}\|^2$ minimal wird. Dies lässt sich so interpretieren, dass ein möglichst einfaches Modell gesucht wird. Wie bei SVM lassen sich durch den Kernel-Trick nicht-lineare Funktionen approximieren und das Optimierungsproblem kann in der dualen Form gelöst werden (vgl. [111]).

Die Gleichung (4.9) entspricht zunächst der Gleichung (4.1). Der Unterschied gegenüber der linearen Regression liegt darin, dass bei SVR nicht die Quadrate der Abweichungen minimiert werden, sondern vielmehr das „einfachste“ Modell gesucht wird, für das alle Abweichungen kleiner als ein festgelegtes ε sind. Dafür muss gewährleistet sein, dass eine solche Lösung überhaupt existiert. In einer Erweiterung des vorgestellten Modells sind auch größere Abweichungen möglich, welche dann durch einen Regularisierungsterm in das Minimierungsproblem aufgenommen werden und damit minimiert werden sollen. Es lassen sich weiterhin der Kernel-Trick und Methoden der Quadratischen Optimierung zur effizienten Lösung des Modells

anwenden.

4.2.4.7 Clustering

Clustering bezeichnet semi-parametrische Methoden zur Analyse von Datensätzen. Im Gegensatz zu den bisher genannten Verfahren geht man bei semi-parametrischen Verfahren nicht von einem Modell aus, welches für den ganzen Eingaberaum gültig ist, sondern nimmt an, dass sich der Eingaberaum in mehrere Untermengen, sogenannte Cluster, unterteilt, für welche jeweils ein eigenes parametrisches Modell zutrifft. Zur Unterteilung des Eingaberaums in entsprechende Cluster sind eine Vielzahl von Verfahren entwickelt worden. Ein Standardverfahren der sogenannten partitionierenden Verfahren ist der k-means-Algorithmus, bei welchem der Datensatz so in k Cluster unterteilt wird, dass die Summe der quadrierten Abweichungen von ebenfalls zu bestimmenden Cluster-Schwerpunkten minimal wird.

In der Regressionsanalyse wird Clustering meist als vorgelagerter Prozess verwendet, um den Datensatz in Untermengen zu unterteilen, für welche dann jeweils separat das gewählte Regressionsmodell angepasst wird. In der Zeitreihenanalyse können so beispielsweise Tage mit ähnlichen Verbrauchsmustern erkannt werden.

4.2.4.8 Weitere

Unter dieser Kategorisierung werden alle Artikel gelistet, welche eine Methode verwenden, die sich nicht einem der genannten Verfahren zuordnen lässt.

4.2.5 Analyse und Synthese

4.2.5.1 Einordnung in Konzeptmatrix

Zur Analyse der gefundenen Literatur wird zunächst eine Übersicht der Einordnung in die Konzeptmatrix gegeben. Diese bietet bereits einen Überblick, welche Methoden für welche Größenordnung zum Einsatz kommen, bei welchen Methoden exogene Variablen verwendet werden und welche Datensätze für die Evaluation von kurzfristigen Stromlastprognosen auf Haushaltsebene zur Verfügung stehen. In dem darauffolgenden Abschnitt wird untersucht, welche Prognosegenauigkeiten jeweils erreicht wurden. Dabei unterstützt die vorherige Einordnung in die Konzeptmatrix die Analyse der Ergebnisse.

Methodenwahl Durch Einordnung der Artikel mithilfe der Konzeptmatrix (vgl. Abb. 4.1) wird deutlich, dass künstliche neuronale Netze mit Abstand am häufigsten für STLTF verwendet werden. Dabei werden hauptsächlich einfache feed-forward-Netzwerke mit einer Hidden-Layer modelliert, welche durch Backpropagation trainiert werden. Weitere häufig verwendete Methoden sind lineare Regression und AR(I)MA-Modelle. Auch Clustering Verfahren werden oft eingesetzt: In drei Artikeln werden ähnliche Zeitabschnitte in den vorausgegangen Daten identifiziert und zur Erstellung der Prognosen genutzt. Eine weitere Clustering Methode wird

Tabelle 4.1: Klassifizierung der für die Forschungsfragen relevanten Artikel anhand der Konzeptmatrix

Art.	Methoden								# Haushalte			Vergleich		
	LR	AR(IMA)	ES	KF	ANN	SVR	Clustering	weitere	1	<100	<1000	exog. var.	intern	öfftl.
[52]				X						X		X		
[107]			X						X	X				
[112]	X	X	X		X				X				X	X
[113]		X			X		X				X	X	X	
[114]							X	X	X				(X)	X
[115]							X		X				(X)	
[116]				X					X			X		
[117]	X				X	X			X		X	X	X	X
[118]	X								X			X		
[119]	X		X		X		X		X			(X)	X	
[120]					X		X				X	X	(X)	X
[121]							X		X			X		
[122]				X	X		X			X				
[123]		X			X	X			X	X	X		X	
[124]		X			X		X		X		X	(X)	X	
[125]	X				X	X	X		X		X	X	X	X
[126]					X				X			X	(X)	
[127]				X					X			X		
#Art.	5	4	3	4	10	3	4	6	14	4	6	13	10	5

in [121] angewendet, bei welcher die Lastgänge verschiedener Haushalte betrachtet und mittels Clustering in verschiedene Haushaltstypen unterteilt werden. Auf Basis der Zuordnung eines Haushaltes zu einem dieser Typen erfolgt die Prognose für die Stromlast. Die Anwendung von Support Vector Regression und exponentieller Glättung wurden jeweils in drei, bzw. vier Artikeln untersucht. Zu den weiteren Ansätzen gehören Modelle basierend auf Wavelet-Transformationen in [114, 124], fallbasiertes Schließen (engl. case-based reasoning) [124] sowie hybride Methoden bereits genannter Methoden wie die Kombination von ARIMA und ANN in [113] und ANN mit Clustering in [120].

Anzahl der Haushalte Die meisten Artikel (14 von 18) untersuchen Ansätze zur kurzfristigen Stromlastprognose von einzelnen Haushalten. Dieses Ergebnis ist nicht überraschend, da der Fokus des Literaturreviews auf Stromlastprognosen im Kontext von Wohneinheiten liegt und daher das Wort „residential“ in den Suchstring aufgenommen wurde. Vier Artikel untersuchen Algorithmen für die kurzfristigen Stromlastprognosen von m aggregierten Haushalten mit $m < 100$. Weitere sechs

Artikel des Reviews evaluieren die entwickelte Methoden für m aggregierte Haushalte mit $100 \leq m < 1000$.

Vergleicht man die Methodenwahl auf Basis der Anzahl der Haushalte sind leichte Tendenzen erkennbar: Für jede Größenordnung werden am häufigsten neuronale Netze verwendet. Lineare Regression und Clustering Methoden werden insbesondere für einzelne Haushalte verwendet. Für mehr als 100 Haushalte kommen hauptsächlich neuronale Netze, SVR und AR(I)MA zum Einsatz. Die jeweils erzielten Prognosegenauigkeiten werden in dem folgenden Unterabschnitt 4.2.5.2 verglichen.

Ein besonderer Einblick in die Skalierbarkeit der verwendeten Methoden wird in denjenigen Artikeln gegeben, welche die Methoden auf Datensätzen in verschiedener Größenordnung erproben. Das sind die Artikel [107, 123–125].

Exogene Variablen Exogene Variablen werden in fast allen Artikeln (14 von 18) verwendet. Dabei wurden bei der Einordnung in die Konzeptmatrix diejenigen Artikel mit X markiert, die exogene Variablen für alle der implementierten Methoden verwenden, und die Artikel, welche sowohl Verfahren mit exogenen Variablen als auch ohne evaluieren, mit einem (X).

Die verwendeten exogenen Variablen sind hauptsächlich Zeitangaben über die Uhrzeit und den Wochentag. Darüber hinaus werden teilweise auch Wettervariablen wie die Temperatur und die Feuchtigkeit als exogene Variablen verwendet. In [119] gehen zudem Angaben über die Anzahl und Eigenschaften der Bewohner in das Modell ein. Die Integration von exogenen Variablen ist in den statistischen Zeitreihenverfahren, AR(I)MA und ES, standardmäßig nicht vorgesehen. Das spiegelt sich in der Konzeptmatrix wider: Drei der vier AR(I)MA-Modelle und alle Verfahren mit exponentieller Glättung lassen keine exogenen Variablen in das Modell einfließen. Das ARIMA-Modell in [113] modelliert die exogenen Variablen als zusätzliche Regressoren und wird damit zu einem sogenannten ARIMAX-Modell. In den weiteren Verfahren ist keine Unterscheidung zwischen exogenen Variablen und Zeitreihenwerten in den Input-Variablen notwendig.

Inwiefern die exogenen Variablen zu einer Verbesserung der Prognosegenauigkeit beitragen, ist aus den Evaluationen meist nicht ersichtlich. In der Evaluation von [119] verbessert sich die Prognosegenauigkeit eines neuronalen Netzes sowie einer linearen Regression durch die Integration von Angaben über die Anzahl und Eigenschaften der Bewohner eines Haushalts. Die Verfahren werden dafür mit den Zeitreihen mehrerer Haushalte trainiert. In [112] werden zwar keine exogenen Variablen in den Methoden selbst verwendet, dafür vorgeschlagen, für jeden Wochentag ein eigenes Modell zu erstellen. Das führt in der Evaluation des Artikels zu verbesserten Ergebnissen bei der linearen Regression, dem ARIMA-Modell und der exponentiellen Glättung. Für das implementierte neuronale Netz werden die Ergebnisse dadurch schlechter.

Interner Vergleich Bei der Einordnung in die Konzeptmatrix wird festgehalten, ob in einem Artikel verschiedene Ansätze ausgewertet und verglichen werden. Da-

bei wird weiterhin erfasst, ob es sich es sich um mehrere verschiedene Methoden handelt oder um die Erweiterungen einer Methode, für welche die Verbesserung gegenüber der Standardmethode aufgezeigt wird. Geht es um den Vergleich verschiedener Methoden, so wird ein X notiert, für den Vergleich einer Erweiterung mit dem Standardverfahren ein (X) (vgl. Tab. 4.1).

Verfügbare Datensätze Unter den zur Evaluation verwendeten Datensätzen sind zwei öffentlich verfügbar. Das ist zum einen das CER Electricity Dataset⁵, welches von dem Irish Social Science Data Archive bereitgestellt wird. Es enthält halbstündliche Verbrauchsdaten von 5000 irischen Haushalten und Unternehmen, aufgenommen in den Jahren 2009 und 2010. Es wird in den Artikeln [120], [114], [117] und [125] verwendet. Zum anderen ist dies das öffentlich verfügbare Reference Energy Disaggregation Dataset (REDD) [128], bereitgestellt von dem Massachusetts Institute of Technology. Der Datensatz enthält die Verbrauchsdaten von sechs Haushalten für 18 Tage im Frühjahr 2011. Die Daten werden in [112] verwendet.

4.2.5.2 Vergleich der Prognosegüte

Um einen Einblick in die erreichbare Prognosegenauigkeit von kurzfristigen Stromlastprognosen zu erhalten und Empfehlungen zur Auswahl der Methoden abzuleiten, werden zum einen die Vergleiche innerhalb der Artikel vorgestellt und zum anderen eine Gegenüberstellung der erreichten Ergebnisse verschiedener Artikel präsentiert.

Vergleich der Methoden innerhalb der Artikel In 10 von 18 Artikeln werden verschiedenen Methoden in der Evaluation ausgewertet und verglichen. Die Ergebnisse der verschiedenen Artikel wirken teilweise widersprüchlich, was an den jeweiligen zugrundeliegenden Datensätzen liegen kann.

Für einzelne Haushalte erzielt in der Auswertung von [123] ein saisonales ARMA-Modell bessere Ergebnisse als ein einfaches neuronales Netz und SVR. Auch in der Evaluation von [124] erreicht ein statistisches Zeitreihenverfahren, ein AR-Modell, eine höhere Genauigkeit als ein neuronales Netz, in diesem Fall ein rekurrentes Netzwerk mit wenigen Verbindungen, und zwei weitere Methoden. Beide Artikel weisen jedoch daraufhin, dass die erzielte Prognosegenauigkeit für einzelne Haushalte nicht besonders hoch ist und man, wenn möglich, mehr als 20 Haushalte aggregieren sollte, um den Prognosefehler zu senken. Dagegen werden in [112] mit einem neuronales Netz geringfügig bessere Ergebnisse für einen einzelnen Haushalt erreicht als mit einem ARIMA-Modell. In den Evaluationen von zwei weiteren Artikeln schneidet eine lineare Regression besser als ein neuronales Netz und SVR ab, solange die Stromlast von weniger als 32 Haushalten prognostiziert werden soll. Nach [107] ist exponentielle Glättung ungeeignet zur kurzfristigen Stromlastprognose von einzelnen Haushalten, da die Prognosegenauigkeit in der Evaluation weitaus schlechter ist als bei dem umgesetzten AR-Modell.

⁵ <http://www.ucd.ie/issda/data/commissionforenergyregulationcer/>, letzter Zugriff am 01.02.2017

Auch für mehr Haushalte kann kein klares Bild gezeichnet werden: In der Auswertung von [123] werden für jede Aggregationsgröße mit einem saisonalen ARMA-Modell bessere Resultate als mit einem neuronalen Netz und SVR erzielt. Die Ergebnisse verbessern sich mit einer steigenden Anzahl von Haushalten bis zur einer kritischen Last von 16MWh/h. Die Artikel [124] und [113] vergleichen u.a. jeweils ein ARMA-Modell mit einem neuronalen Netz für die Stromlastprognose von 128, bzw. 150 Haushalten. Dabei wird in [113] eine Kombination der beiden Verfahren favorisiert. In [124] sind auch für 150 Haushalte die Ergebnisse des AR-Modells besser als bei einem neuronalen Netz. SVR sind nach den Resultaten von [117] ab einem Aggregationsniveau von 32 Wohnungen der linearen Regression und einem neuronalen Netz vorzuziehen.

Vergleich der Methoden zwischen den Artikeln Die Ergebnisse der verschiedenen Artikel zu vergleichen, gestaltet sich insofern schwierig, als dass sich die Auswertungen nicht nur in der Anzahl der Haushalte, sondern auch in der Länge der Prognosezeiträume, den zugrundeliegenden Zeitintervallen und in der Wahl der Kennzahlen unterscheiden. In Tab. 4.2 sind die jeweils besten Resultate eines Artikels dargestellt, sofern eine der drei folgenden Kennzahlen verwendet wurde: (1) Mean Average Percentage Error (MAPE), (2) Root Mean Squared Error (RMSE) oder (3) der Normalized Root Mean Squared Error (NMRSE) nach der Definition von [125].

Die Ergebnisse unterscheiden sich erheblich, so liegt der MAPE der Stromlastprognosen für die nächste halbe Stunde in [126] für einzelne Haushalte bei 7%, während die Prognosen in [112] für dasselbe Setting einen MAPE von 49% aufweisen. Die genannten Ergebnisse wurden in beiden Fällen mit einem neuronalen Netz erreicht. Soll die Stromlast für die nächste Stunde prognostiziert werden, sind die Ergebnisse homogener: In [126] wird ein MAPE von 30%, in [112] von 47% angegeben. Bei der Prognose einer einstündigen Stromlast 24 Stunden im Voraus wird in [112] ein MAPE von 46% und in [107] ein MAPE von 63% erreicht. Je mehr Haushalte aggregiert werden, desto genauer und homogener werden die Ergebnisse: Für mehr als 100 Haushalte wird bei einem Prognosezeitraum von 24 h in drei unterschiedlichen Artikeln jeweils ein MAPE zwischen 4% und 5% angegeben.

Anhand dieser Tabelle lassen sich schwer Rückschlüsse auf die Prognosegüte der jeweiligen Methoden ziehen, da ähnliche Methoden in der Evaluation unterschiedlicher Artikel zu sehr unterschiedlichen Fehlern führen. Diese Unterschiede unterstreichen die Annahme, dass die Prognosegenauigkeit sehr stark von dem zugrundeliegenden Datensatz abhängt und dass für einen Vergleich der Methoden diese auf demselben Datensatz ausgewertet werden sollten.

4.2.6 Zusammenfassung und Schlussfolgerungen

Anhand einer umfassenden Literaturrecherche wurde der aktuelle Forschungsstand zu kurzfristigen Prognosen von Stromlasten in Wohngebäuden und kleinen Wohnsiedlung aufgezeigt. Durch die Einordnung der vorhandenen Ansätze in eine Kon-

Tabelle 4.2: Vergleich der Prognosegenauigkeit der verschiedenen Ansätze anhand der angegebenen Kennzahlen in den Artikeln (Art.); Unter dem Setting wird beschrieben, wie viele Haushalte in der Prognose aggregiert wurden, für welchen Zeitraum die Prognose erstellt wurde und welche zeitliche Intervallgröße den Stromlastdaten zugrunde liegt; Wenn der verwendete Datensatz öffentlich verfügbar ist, ist er in der Spalte Daten spezifiziert.

Art.	Setting			Kennzahlen			Meth.	Daten
	# Haushalte	Prognose-zeitraum	Intervallgröße	MAPE	NRMSE	RMSE		
[116]	1	15 min	15 min	13%	–	–	KF	–
[112]	1	15 min	15 min	48%	–	–	AR	REDD
[126]	1	30 min	30 min	7,3%	–	–	ANN	–
[116]	1	30 min	30 min	18%	–	–	KF	–
[112]	1	30 min	30 min	49%	–	–	ANN	REDD
[117, 125]	1	1 h	1 h	–	0,56	–	LR	CER
[124]	1	1 h	1 h	–	–	0,5kWh	KF	–
[116]	1	1 h	1 h	30,4%	–	–	KF	–
[112]	1	1 h	1 h	47%	–	–	AR	REDD
[112]	1	24 h	1 h	46%	–	–	LR	REDD
[107]	1	24 h	1 h	62,6%	–	–	ES	–
[117, 125]	1	24 h	1 h	–	0.61	–	LR	CER
[52]	30	24 h	1 h	13%	–	–	KF	–
[117, 125]	782	1 h	1 h	3,4%	–	–	SVR	CER
[124]	150	24 h	1 h	–	–	21kWh	AR	–
[120]	230	24 h	1 h	5%	–	–	ANN	CER
[117, 125]	782	24 h	1 h	4,3%	0,06	54kWh	SVR	CER

zeptmatrix wurde die vorhandene Literatur gemäß ihrer Methodik und der Zielsetzung geordnet. Die meistverwendeten Methoden wurden in ihren Grundzügen vorgestellt und die Ergebnisse – soweit möglich – gegenüber gestellt.

Der Vergleich der Ergebnisse erweist sich als sehr schwierig, da zum einen unterschiedliche Prognosezeiträume evaluiert werden, die Größe der Zeitintervalle der zugrundeliegenden Datenreihe variiert und verschiedene Kennzahlen zur Messung der Prognosegüte verwendet werden. Zum anderen werden die entwickelten Methoden oft nur auf projekt-internen Datensätzen ausgewertet, so dass die Ergebnisse eines Artikels – selbst wenn das grundlegende Setting dasselbe ist – nicht mit den Ergebnissen anderer Artikel verglichen werden können. Dies wird deutlich, wenn zwei verschiedene Artikel mit jeweils einem neuronalen Netz einmal einen MAPE von 7% [126] und einmal von 49% [112] für dasselbe Setting angeben.

Anhand der durchgeführten Gegenüberstellung können dennoch gewisse Ten-

denzen abgeleitet werden: Die vielversprechendsten Methoden scheinen neuronale Netze und AR(I)MA-Modelle zu sein. Für einzelne Haushalte wurden vergleichsweise gute Ergebnisse auch mit linearer Regression erreicht. Für mehr als 30 Haushalte sind teilweise bessere Ergebnisse mit SVR erzielt worden. Die Ansätze verschiedene Methoden wie ANN und ARIMA zu kombinieren oder die genannten Methoden durch Cluster zu ergänzen, haben teilweise zu einer Verbesserung gegenüber dem Standardverfahren geführt.

Insgesamt wird deutlich, dass es sich um ein Forschungsthema handelt, welches in den letzten Jahren an Bedeutung gewonnen und für welches sich noch keine Methode als die überlegene herausgestellt hat. Für die weitere Forschung zu kurzfristigen Stromlastprognosen für einzelne Haushalte und Microgrids ist eine Auswertung der vielversprechenden Ansätze auf öffentlich verfügbaren Datensätzen unerlässlich, um so verlässliche Ergebnisse zu erhalten, die auch für ein Benchmarking und so für die weitere Entwicklung von STLF verwendet werden können.

4.3 Experimente

In der vorausgehenden Literaturrecherche wurde deutlich, dass sich die bisher verwendeten Ansätze für STLF nur schwer vergleichen lassen, da sie auf unterschiedlichen, oft nicht öffentlich verfügbaren Datensätzen evaluiert wurden. Diese Forschungslücke soll in dieser Arbeit durch die Implementierung von sechs State-of-the-Art Methoden und der Evaluierung derselben auf drei verschiedenen Datensätzen geschlossen werden. Dazu werden anknüpfend an die Empfehlungen aus dem vorausgehenden Abschnitt ein AR-Modell, eine lineare Regression und ein neuronales Netz implementiert. Zusätzlich werden drei weitere Verfahren aus dem Bereich des maschinellen Lernen in die Auswertung aufgenommen, nämlich eine k-nächste-Nachbarn-Regression, Entscheidungsbäume und Random Forests. Zudem werden zwei sehr einfache Verfahren, in welchen einmal der Durchschnittswert für die jeweilige Tageszeit prognostiziert und einmal der vorausgehende Wert prognostiziert wird.

Durch den explorativen Ansatz wird ein Vergleich der verschiedenen Methoden möglich und es können Empfehlungen für die Auswahl abgeleitet werden. In der Evaluation werden verschiedene Prognosezeiträume und verschiedene Aggregationsstufen betrachtet, um so eine systematische Analyse der Fehlerentwicklung in Abhängigkeit dieser Komponenten zu geben.

In diesem Abschnitt wird der Aufbau der Experimente beschrieben. Dazu werden zunächst die Datensätze vorgestellt, welche zur Evaluation verwendet werden. Es wurden drei öffentlich verfügbare Datensätze ausgewählt, die jeweils die Stromverbrauchsdaten von mehreren Haushalten enthalten und die somit eine Analyse der Skalierbarkeit der STLF Methoden zulassen. Es wird eine Aufteilung in verschiedene Aggregationsstufen vorgestellt. Im Anschluss werden die Methoden vorgestellt, welche in der Auswertung verwendet werden. Der darauffolgende Unterabschnitt beschreibt die Input-Variablen, welche sich aus vergangenen Werten der Zeitreihen

und exogenen Variablen zusammensetzen. Es wird die Aufteilung von Trainings- und Testdaten beschrieben sowie geeignete Kennzahlen zur Auswertung der Prognosen vorgestellt. Die Analyse der Ergebnisse folgt im darauffolgenden Abschnitt 4.4.

4.3.1 Daten

4.3.1.1 Datensätze

Bis ungefähr 2014 war es sehr schwierig, Datensätze zum Stromverbrauch einzelner Haushalte zu erhalten, da diese nur in vereinzelten Projekten aufgezeichnet wurden und ggf. entsprechenden Datenschutzbedingungen unterlagen, durch welche verhindert wurde, dass sie zur Forschung öffentlich zugänglich waren. Dies hat sich mit der zunehmenden Installation von Smart Metern geändert. Inzwischen sind mehrere öffentlich zugängliche Datensätze zum Stromverbrauch von einzelnen Haushalten verfügbar. Für die Experimente in diesen Artikeln werden zwei Datensätze ausgewählt, die bereits für die Evaluierung von STLF-Methoden verwendet wurden. Dies sind das *Reference Energy Disaggregation Dataset* [128] (REDD) und das *CER Electricity Dataset* (CER) der irischen Commission for Energy Regulation⁶. Zusätzlich wird der REFIT Datensatz [48] verwendet, welcher die Stromlastdaten von 20 Wohnungen enthält und in Kapitel 2 bereits zur Modellierung des Microgrids verwendet wurde.

Die Datensätze haben unterschiedliche Formate und Aufzeichnungsdichten. Für die Auswertung in der vorliegenden Arbeit werden sie jeweils in äquidistante Zeitreihen transformiert, die den Stromverbrauch von halbstündlichen Zeitintervallen enthalten. Die Größe des Zeitintervalls wurde aus Vergleichszwecken auf eine halbe Stunde festgelegt, da der umfangreichste Datensatz, CER, Zeitreihen mit halbstündlichen Messwerten enthält.

Die Datensätze, welche mehrere Datenreihen über den Verbrauch einzelner Haushalte enthalten, werden genutzt, um die Skalierungseffekte der STLF Methoden zu untersuchen. Dafür werden die Datenreihen einzeln und in verschiedenen Aggregationsstufen betrachtet. Dies wird in der folgenden Beschreibung der Datensätze ausgeführt. Für jede Datenreihe wird der Variationskoeffizient angegeben. Dieser Wert berechnet sich aus der Division der Standardabweichung durch den Erwartungswert und ist ein Maß der Variabilität einer Datenreihe. In Absatz 4.2.2.2 wurde bereits darauf hingewiesen, dass dieser Wert für aggregierte Datenreihen mehrerer Haushalte abnimmt. In der nachfolgenden Analyse wird untersucht, ob ein Zusammenhang zwischen dem Variationskoeffizienten und der Prognosegenauigkeit besteht.

REDD Der Reference Energy Disaggregation Dataset wird vom Massachusetts Institute of Technology zur Verfügung gestellt. Es enthält die Stromverbrauchsdaten von sechs Haushalten in Massachusetts für 18 Tage im Frühjahr 2011. Der Datensatz beinhaltet hochfrequente und niederfrequente Messwerte, welche mit einer

⁶ <http://www.ucd.ie/issda/data/commissionforenergyregulationcer/>, letzter Zugriff am 01.02.2017

Abtastrate von ca. drei Sekunden erfasst wurden. Er umfasst sowohl die Messwerte der Hauptstromkreise sowie die Messwerte von einzelnen Geräten wie Lampen, Mikrowellen und Kühlschränken.

Der Datensatz wurde bereits in der Evaluation von STLF in [112] verwendet. Der Datenauswahl dieses Artikels folgend werden die niederfrequenten Messwerte der einzelnen Geräte von Haus 1 aggregiert und in eine Datenreihe transformiert, welche den Stromverbrauch von fest definierten Zeitintervallen angibt. Die Aufzeichnungen der weiteren Haushalte sind zu unregelmäßig, als dass sie für die Evaluation verwendet werden könnten. Aus der transformierten Datenreihe mit halbstündlichen Zeitintervallen wird der längste zusammenhängende Abschnitt ohne fehlende Daten ausgewählt. Die so erhaltene Zeitreihe beginnt am 18. April 2011 22:00:00 GMT und endet am 2. Mai 22:00:00 GMT. Der durchschnittliche halbstündliche Stromverbrauch μ beträgt 285 Wh und die Standardabweichung σ liegt bei 345 Wh. Der Variationskoeffizient μ/σ , welcher die Standardabweichung relativ zum Durchschnittswert angibt, beträgt 121%.

CER Das CER Electricity Dataset beinhaltet halbstündliche Verbrauchsdaten von fast 5000 irischen Haushalten und Unternehmen, die zwischen 2009 und 2010 aufgezeichnet wurden. Es wurde bereits in [114, 117, 125] zur Evaluation von STLF verwendet. Anhand der Beschreibung in den Artikeln ist nicht erkennbar, welche Daten des Datensatzes in den Auswertungen verwendet wurden. Für die Auswertung in dieser Arbeit wurden 100 Datenreihen ausgewählt, für welche die Messwerte die folgenden drei Kriterien erfüllen:

1. Die Datenreihe liegt vom 09.08.2009 bis 04.12.2010 vollständig vor. Dieser Zeitraum wurde zuvor als Zeitraum identifiziert, den viele Zeitreihen gemeinsam haben.
2. Der durchschnittliche Jahresverbrauch ist größer als 500 kWh und kleiner als 20.000 kWh. Damit sollen diejenigen Datensätze ausgeschlossen werden, die entweder in teilweise unbewohnten Gebäuden oder offensichtlich nicht in einem Haushalt aufgezeichnet wurden (vgl. Datensatz 1001 in Abb. 4.4).
3. Der Stromverbrauch von vier aufeinanderfolgenden Wochen soll sich nicht um den Faktor zwei von dem Stromverbrauch der nachfolgenden vier Wochen unterscheiden. Damit sollen Daten ausgeschlossen werden, die sprunghaft einsetzende, andauernde Veränderung beinhalten, da dies nicht dem üblichen Verbrauchsverhalten von Haushalten entspricht (vgl. Datensatz 1028 Abb. 4.4).

Zu der Auswahl wurde eine Routine implementiert, welche aus den knapp 5000 Datenreihen die ersten 100 ausgewählt hat, welche die genannten Kriterien erfüllen. Die ausgewählten Datensätze sind die Haushalte mit den Nummern in $H_{CER} := \{1000, 1003, 1004, 1005, 1007, 1008, 1009, 1013, 1014, 1015, 1018, 1019, 1020, 1024, 1025, 1027, 1029, 1030, 1031, 1033, 1034, 1037, 1039, 1041, 1044, 1046, 1047, 1051, 1054, 1057, 1059, 1060, 1061, 1063, 1065, 1066, 1067, 1071, 1073, 1075, 1076, 1077,$




Abbildung 4.4: Beispielabschnitte aussortierter Datensätze(jeweils 14 Wochen): Der Verbrauch im Datensatz 1001 ist durchschnittlich zu hoch und verstößt somit gegen Bedingung 2. Der hohe Verbrauch und der regelmäßige Wochenverlauf deuten auf ein Unternehmen hin. Der Verbrauch im Datensatz 1028 verändert sich teilweise sehr sprunghaft. Der Haushalt scheint über Wochen hinweg unbewohnt zu sein.

1079, 1081, 1082, 1083, 1084, 1085, 1087, 1088, 1091, 1093, 1096, 1097, 1098, 1099, 1100, 1105, 1107, 1108, 1109, 1110, 1111, 1115, 1117, 1118, 1119, 1121, 1122, 1123, 1124, 1125, 1128, 1129, 1130, 1132, 1133, 1136, 1138, 1139, 1140, 1141, 1143, 1144, 1148, 1154, 1155, 1156, 1157, 1162, 1164, 1165, 1168, 1170, 1174, 1176, 1178, 1180, 1182, 1183}.

Auch wenn für die einzelnen Datensätze teilweise zusammenhängende Messreihen vorliegen, welche über den für alle gemeinsamen Zeitraum hinausgehen, erfolgt die Auswertung ausschließlich für den spezifizierten Zeitraum vom 09.08.2009 bis zum 04.12.2010, um die Ergebnisse besser vergleichen zu können. Auf diese Weise wird auch die Aggregation der Datensätze verschiedener Haushalte möglich. Der CER-Datensatz eignet sich sehr gut dazu, die Skalierungseffekte der STLF Methoden zu untersuchen. Die Menge der 100 Haushalte wird in fünf verschiedenen Aggregationsstufen zur Evaluation der STLF Methoden verwendet:

1. Es werden Prognosen für jeden einzelnen Haushalt erstellt und die durchschnittliche Prognosegenauigkeit betrachtet.
2. Die Menge wird in 33 disjunkte Untermengen, bestehend aus jeweils drei (in H_{CER} aufeinanderfolgenden) Haushalten, unterteilt: $\{1000, 1003, 1004\}$,

Tabelle 4.3: Datensätze für die Evaluation der kurzfristigen Stromlastprognosen; In der Spalte # Reihen ist angegeben, wie viele Zeitreihen für diesen Datensatz evaluiert werden, # agg. H. gibt an, wie viele Haushalte in den Zeitreihen aggregiert wurden. Die Spalten μ und μ/σ geben jeweils an, in welchen Bereichen der durchschnittliche halbstündliche Stromverbrauch und der Variationskoeffizient der Zeitreihen liegt.

Name	Datensatz	# Reihen	# agg. H.	# Tage	μ [kWh]	σ/μ [%]
REDD	REDD	1	1	15	0,3	121
CER ₁	CER	100	1	482	0,1-1,1	57-228
CER ₃	CER	33	3	482	0,6-1,9	57-108
CER ₁₀	CER	10	10	482	4,8-6,6	54-64
CER ₃₀	CER	3	30	482	15,7-18,3	47-53
CER ₁₀₀	CER	1	100	482	55,4	48
RFT ₁	REFIT	12	1	340	0,2-0,7	60-143
RFT ₃	REFIT	4	3	340	1,1-1,7	53-75
RFT ₁₀	REFIT	1	10	340	4,7	50

$\{1005, 1007, 1008\}, \dots, \{1178, 1180, 1182\}$. Für die aggregierten Zeitreihen dieser Untermengen werden jeweils Prognosen erstellt und die durchschnittliche Prognosegenauigkeit betrachtet.

3. Nach demselben Prinzip werden Prognosen für den aggregierten Verbrauch von 10 Haushalten in 10 disjunkten Untermengen,
4. Prognosen für den aggregierten Verbrauch von 30 Haushalten in 3 Untermengen und
5. Prognosen für den aggregierten Verbrauch aller 100 genannten Haushalten analysiert.

Eine Übersicht der erstellten Datensätze ist in Tab. 4.3 gegeben. Die annähernd logarithistische Erhöhung der Anzahl von Wohnungen soll Aufschluss über die Entwicklung der Fehler in Abhängigkeit von der Anzahl der Wohnungen geben.

Der durchschnittliche halbstündliche Stromverbrauch μ der einzelnen Haushalt variiert zwischen 123 Wh und 1127 Wh. Die Variationskoeffizienten liegen zwischen 57% und 228%. Sie werden mit einer steigenden Anzahl von Haushalten für alle Datenreihen kleiner. Der Variationskoeffizient für die aus 100 Datensätzen aggregierte Zeitreihe beträgt 48%.

REFIT Das REFIT Electrical Load Measurements Dataset ist im Rahmen des REFIT-Projektes veröffentlicht worden (vgl. [48]). Der Datensatz enthält die Wirkleistungsmessungen von 20 Haushalten in Großbritannien sowie die Messwerte von Einzelgeräten in den Haushalten mit einer Abtastrate von weniger als einer Minute. Zur Auswertung werden die Messdaten in Zeitreihen transformiert, welche den halbstündlichen Stromverbrauch des jeweiligen Haushaltes angeben. Es werden die

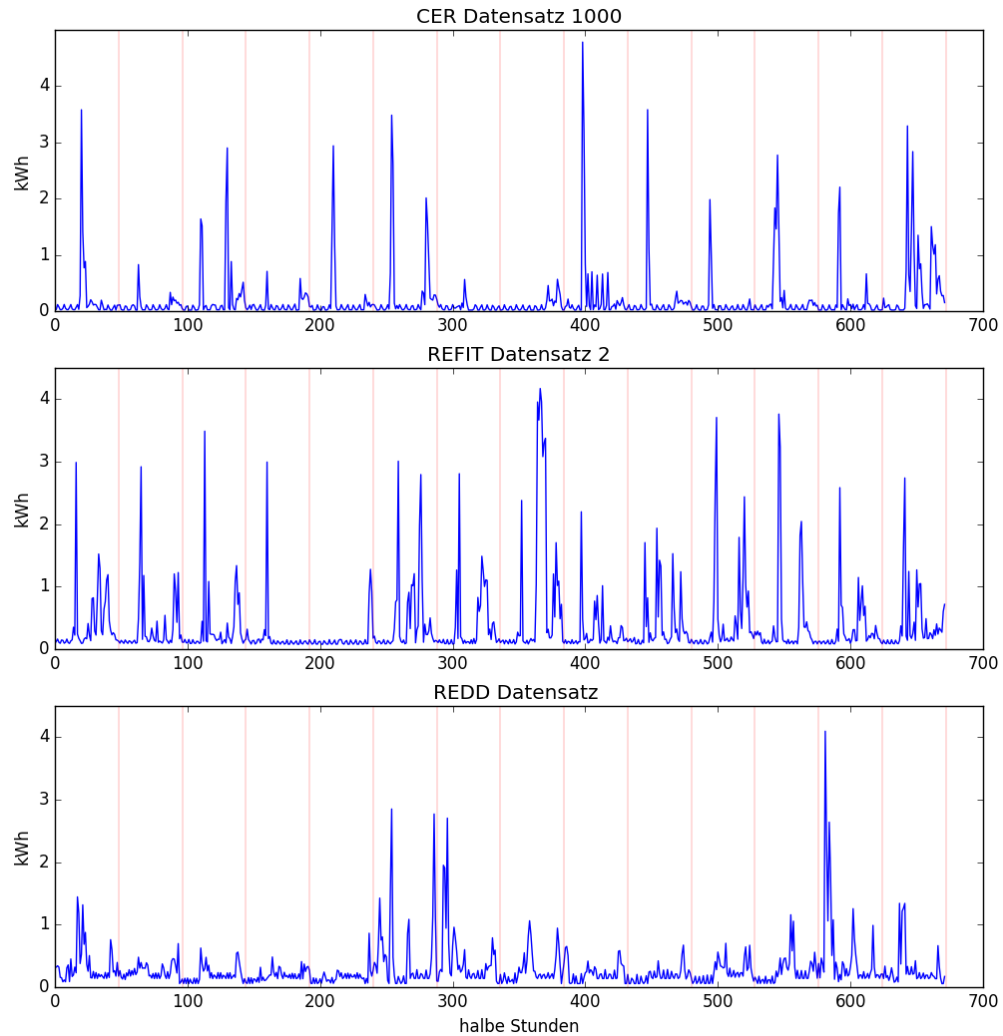


Abbildung 4.5: Beispiele von drei verwendeten Datensätzen: Es sind die ersten zwei Wochen des Datensatzes 1000 aus CER, des Datensatzes 2 aus REFIT und dem REDD Datensatz dargestellt. Die vertikalen rosa Linien markieren jeweils den Beginn eines Tages. Auf den ersten beiden Zeitreihen lässt sich ein morgendlicher Peak im Stromverbrauch erkennen.

Daten der zwölf Häuser 2, 3, 4, 6, 7, 10, 11, 15, 17, 18, 19 und 20 analysiert, welche bereits in Kapitel 2 zur Modellierung des Stromverbrauchs im Microgrid verwendet wurden. Der Datenreihe umfasst 340 Tage, beginnend am 04. Juni 2014.

Auf diesem Datensatz werden ebenfalls die Skalierungseffekte untersucht und die Prognosegenauigkeit für den Stromverbrauch der einzelnen Wohnungen mit der Prognosegenauigkeit für drei, bzw. zehn Wohnungen verglichen. Eine Übersicht aller verwendeten Datensätze ist in Tab. 4.3 gegeben. Insgesamt werden die Prognosen auf 165 Zeitreihen evaluiert (vgl. Tab. 4.3). In Abb. 4.5 sind Ausschnitte der verwendeten Datenreihen visualisiert.

4.3.2 Trainings- und Testmengen

Sei $(Y_t)_{t \in T}$ die jeweils komplette vorliegende Datenreihe. Zu einem Zeitpunkt $t \in T$, bzw. am Ende eines Zeitintervalls t , soll ein zukünftiger Zeitreihenwert Y_{t+h} geschätzt werden. Dafür werden die Prognoseverfahren auf einer Trainingsmenge $\{(Y_s, \mathbf{x}_s)\}_{s \in S}$ mit $s \leq t \forall s \in S \subset T$ trainiert. Der Vektor $\mathbf{x}_s \in \mathbb{R}^v$ enthalte dazu jeweils v Variablen, für welche die statistische Verknüpfung zu Y_s modelliert werden soll. Die Komponenten der \mathbf{x} -Werte werden als Input-Variablen bezeichnet und können je nach Methode zurückliegende Variablen der Zeitreihe wie beispielsweise Y_{s-1} oder exogene Variablen enthalten. Die Wahl der Input-Variablen wird in Abschnitt 4.3.4 beschrieben. Es bezeichne $\mathcal{X} := \{\mathbf{x}_s\}_{s \in S}$ die Menge der \mathbf{x} -Werte in der Trainingsmenge.

In der vorliegenden Arbeit wird die sogenannte *Sliding Window*-Strategie zur fortlaufenden Prognose verwendet, das heißt statt einer einmaligen Aufteilung des Datensatzes in Trainings- und Testdaten erfolgt nach einem gewissen Zeitintervall ein Update des Trainingsdatensatzes und das Modell wird neu trainiert. Eine Veranschaulichung der Strategie ist in Abb. 4.6 dargestellt.



Abbildung 4.6: Sliding Window Strategie angelehnt an die Darstellung in [112].

Auf diese Weise werden weiter zurückliegende Daten aus der Trainingsmenge entfernt und durch aktuellere ersetzt. Der Vorteil liegt darin, dass sich das Modell so auf sich verändernde Muster anpasst. Das kann bei Stromverbrauchsdaten zum Beispiel die Einführung einer strom-intensiven Kochrunde am Sonntagabend sein. In der vorliegenden Arbeit erfolgt jeweils nach einem Tag ein Update der Trainingsmenge. Die Länge der Trainingsmenge wird einmal auf 4/5 der Länge des kompletten Zeitreihe (das heißt 385 für die CER-Datensätze und 272 Tage für den REFIT-Datensätze) gesetzt und einmal eine Trainingsmenge von 91 Tagen getestet, dies entspricht einem Vierteljahr. Für den REDD-Datensatz wird ein Trainingszeitraum von sieben Tagen gewählt, um die Ergebnisse mit den Befunden aus [112] vergleichen zu können.

Es werden Prognosen für $h = 1, 4, 8, 16, 48$ evaluiert, das heißt Prognosen für den Verbrauch der nächsten halben Stunde sowie für den halbstündlichen Verbrauch 2 Stunden im Voraus, 4 Stunden im Voraus, 8 Stunden im Voraus und 24 Stunden im Voraus. Dadurch kann in der nachfolgenden Analyse untersucht werden, wie sich der Fehler mit zunehmendem Prognosehorizont entwickelt.

4.3.3 Methoden

In den Experimenten werden sechs verschiedene Methoden zur Prognose der Stromlasten betrachtet. Dazu gehören saisonale AR-Modelle sowie neuronale Netze, da diese Verfahren in der betrachteten Literatur – soweit vergleichbar – die besten Resultate für STLTF für einzelne Wohngebäude erzielen. Da man davon ausgehen

kann, dass das Verhalten, welches zu dem Stromverbrauch eines einzelnen Haushaltes führt, prinzipiell nicht linear ist, werden weitere nicht-parametrische Modelle aus dem Bereich des maschinellen Lernen implementiert, welche die Muster im Stromverbrauch erkennen sollen. Das sind k-nächste Nachbarn, Regressionsbäume und Random Forests. Zudem wird eine lineare Regression, welche für jede halbe Stunde des Tages ein eigenes Regressionsmodell aufstellt, und zwei sehr einfache Prognoseverfahren zu Vergleichszwecken implementiert. Die genannten Verfahren werden im Folgenden vorgestellt. In [102] sind bereits Ergebnisse dieser Methoden für stündliche Prognosen veröffentlicht. Dabei wurde darüber hinaus eine *Kernel-Ridge-Regression* untersucht, da diese jedoch auf keinem der untersuchten Datensätze zu kompetitiven Resultaten geführt hat, wurde auf die weitere Analyse des Verfahrens verzichtet.

4.3.3.1 AR-Modelle

Autoregressive Integrated moving Average (ARIMA) Modelle sind statistische Zeitreihenverfahren (vgl. Absatz 4.2.4.2), die gemäß der durchgeführten Literaturrecherche neben neuronalen Netzen bisher zu den besten Ergebnissen bei der Prognose von kurzfristigen Stromlastprognosen einzelner Haushalte geführt haben. Dabei wurde in der Studie von [124] ein reines AR-Modell, in [113] ein AR-Modell mit exogenen Variablen, in [112] ein nicht näher spezifiziertes ARIMA-Modell und in [123] ein saisonales AR-Modell implementiert.

Zur Identifikation eines geeigneten ARIMA-Modells wird eine Analyse der Zeitreihen durchgeführt (vgl. [129]). Zunächst wird geprüft, ob angenommen werden kann, dass die Zeitreihen stationär sind oder ob ggf. die Differenzen der Zeitreihenwerte betrachtet werden sollten. Mittels des Augmented Dickey-Fuller-Tests (ADF-Test) werden die Zeitreihen auf Differenzen-Stationarität untersucht. Die Ergebnisse der Tests sind im Appendix A.1 zu finden. Diesen zufolge können stochastische Trends ausgeschlossen werden und es wird daher ein ARMA-Modell und kein integriertes Modell betrachtet. Zur weiteren Analyse werden die empirisch geschätzten Autokorrelationen und partiellen Autokorrelationen betrachtet. Die Autokorrelationfunktion () gibt Aufschluss darüber, wie sehr die Zufallsvariablen Y_t und Y_{t+h} für ein $h \in \mathbb{N}$ in einem stationären stochastischen Prozess korreliert sind. Die partielle Autokorrelationfunktion (PACF) gibt Aufschluss über die Korrelation der Variablen, wenn der Einfluss der dazwischen liegenden Variablen herausgerechnet wird. Ist das stochastische Modell bekannt, so werden die Funktionen aus den Kovarianzen berechnet. Die empirischen Autokorrelationen werden aus den geschätzten Kovarianzen einer gegebenen Zeitreihe ermittelt. Für die mathematischen Definitionen sei auf Lehrbücher der statistischen Zeitreihenanalyse wie beispielsweise [129] verwiesen.

In den Abb. 4.7, 4.8 und 4.9 sind die empirischen Autokorrelationsfunktionen für $h = 1, \dots, 96$ der Zeitreihen der einzelnen Haushalte dargestellt. Für die Zeitreihen aus REFIT und CER werden die Werte der Korrelationsfunktionen in Boxplots abgebildet. Dabei sind in den Zeitreihen aus den REFIT und CER Datensatz deutliche saisonale Abhängigkeiten für eine Saisonlänge von $h = 48$, also einem Tag,




Abbildung 4.7: Empirische Autokorrelation und partielle Autokorrelation der Zeitreihe REDD.




Abbildung 4.8: Boxplots zu der empirischen Autokorrelation und partiellen Autokorrelation der Zeitreihen aus REFIT.




Abbildung 4.9: Boxplots zu der empirischen Autokorrelation und partiellen Autokorrelation der Zeitreihen aus CER.

erkennbar. Die saisonalen Anteile können stochastisch und deterministisch modelliert werden. Beide Ansätze werden im Folgenden betrachtet:

AR-Modell mit stochastischen Saisonkomponenten Wie in [123] wird ein saisonales AR-Modell (*SAR*) mit stochastischen Saisonkomponenten gewählt, wobei die Saisonlänge mit einem Tag modelliert wird. Der Beschreibung dieses Artikels folgend wird die Saisonalität durch additive, autoregressive Komponenten modelliert und die Zeitreihe als folgender stochastischer Prozess interpretiert:

$$Y_t = \sum_{r=1}^p \phi_r(Y_{t-r}) + \sum_{l=1}^P \Phi_l(Y_{t-dl}) + \varepsilon_t, \quad (4.10)$$

wobei $d = 48$ die Länge einer Saison beschreibt und angenommen wird, dass ε_t für alle t normalverteilt sei. Das Modell wird als $\text{AR}(p) \times (P)_d$ bezeichnet. Als Modellparameter werden die Ordnungen $p = 1, 2, 3$ und $P = 1$ evaluiert. Nur für die Zeitreihe des REDD-Datensatzes wird $P = 0$ gesetzt, da in den Autokorrelationen keine saisonale Abhängigkeiten erkennbar sind. Die Regressionskoeffizienten $\{\phi_r\}_{r=1,\dots,p}$ und $\{\Phi_l\}_{l=1,\dots,P}$ werden jeweils durch die Methode der kleinsten Quadrate auf der Trainingsmenge bestimmt.

ARMA-Modell mit deterministischen Saisonkomponenten In diesem Modell werden die saisonalen Anteile als additive, deterministische Komponenten mo-

delliert. Sie werden auf Basis der Trainingsmenge geschätzt, welche eine Länge $n = m \cdot d$ Zeiteinheiten umfasst, m bezeichne die Anzahl von vollständigen Tagen in der Trainingsmenge. Dann wird für $r = 1, \dots, d$ der saisonale Anteil

$$s_r = \frac{1}{m} \sum_{j=1}^m Y_{r+(j-1) \cdot d}$$

geschätzt. Die saisonalen Anteile werden periodisch mit $s_t = s_{t-d}$ für $t > d$ fortgesetzt und die Datenreihe bzgl. der saisonalen Komponenten bereinigt:

$$Y'_t = Y_t - s_t \quad \forall t \in T.$$

Für die saisonbereinigten Zeitreihen Y' liegen ebenfalls keine stochastischen Trends vor, da die Schlussfolgerungen des ADF-Tests auch nach Abzug der saisonalen Durchschnittswerte gelten (vgl. [130]). Die Zeitreihen werden als nicht integriertes ARMA(p,q)-Modell modelliert. Zur Schätzung der Ordnungen p und q werden die empirischen Autokorrelationsfunktionen und die empirischen partiellen Autokorrelationsfunktionen der saisonbereinigten Zeitreihen betrachtet. In den Abb. 4.10 und 4.11 sind die empirischen ACF und PACF für $h = 1, \dots, 48$ für die saisonbereinigten Zeitreihen der einzelnen Haushalte der REFIT und CER-Datensätze dargestellt. Wie zuvor werden Boxplots zur Darstellung verwendet. Zudem sind die Konfidenzschranken des 95%-Konfidenzintervalls eines stochastischen Prozesses mit identisch und unabhängig verteilten Zufallsvariablen dargestellt. Die empirische Autokorrelation nimmt für alle Zeitreihen bei steigendem Abstand h annähernd exponentiell ab. Die empirische PACF befindet sich für die meisten der Zeitreihen für $h > 5$ in dem Konfidenzintervall. Die Beobachtungen legen nahe, dass sich die Zeitreihen am besten mit reinen AR-Modelle mit $p \leq 5$ approximieren lassen.

Für die Zeitreihen aus dem REFIT-Datensatz werden AR(p)-Modelle mit $p \in \{2, 3, 4, 5\}$ evaluiert, die Zeitreihen aus dem CER-Datensatz mit $p \in \{1, 2, 3, 4, 5\}$. Für den REDD-Datensatz wird dieses Modell nicht betrachtet, da keine saisonalen Komponenten erkennbar sind und reine AR(p)-Modelle für die originale Zeitreihe von REDD in dem Ansatz mit stochastischen Saisonanteilen mit $Q = 0$ bereits modelliert wurden. Die Regressionskoeffizienten werden ebenfalls mit der Methode der kleinsten Quadrate bestimmt. Im Folgenden wird dieses Modell als AR^+ referenziert.

4.3.3.2 Lineare Regression

Die Funktionsweise der lineare Regression (LR) wird in der Literaturanalyse in Absatz 4.2.4.1 beschrieben. Zur Modellierung der Stromlasten wird für jede halbe Stunde eines Tages ein eigenes Regressionsmodell entwickelt, um so den unterschiedlichen Verbrauchsmustern eines Tages gerecht zu werden. Als Input-Variablen werden vorausgehende Zeitreihenwerte verwendet. Es wird eine Auswahl an Input-Variablen getestet, die in dem kommenden Abschnitt 4.3.4 beschrieben wird.

Die Regressionskoeffizienten der 48 LR-Modelle werden mit der Methode der kleinsten Quadrate bestimmt.




Abbildung 4.10: Boxplots zu der empirischen Autokorrelation und partiellen Autokorrelation der saisonbereinigten Zeitreihen aus REFIT mit 95%-Konfidenzintervall.




Abbildung 4.11: Boxplots zu der empirischen Autokorrelation und partiellen Autokorrelation der saisonbereinigten Zeitreihen aus CER mit 95%-Konfidenzintervall.

4.3.3.3 Künstliche Neuronale Netzwerke

Künstliche neuronale Netze/Netzwerke (engl. Artificial neural networks, kurz *ANN*) gehören nach der durchgeführten Literaturrecherche zu den meist angewendeten und erfolgreichsten Methoden, die für STLF von Wohngebäuden zum Einsatz gekommen sind. Das grundlegende Konzept des Verfahrens wird innerhalb der Literaturrecherche 4.2.4.5 erläutert.

Den bisher angewandten Modellen (vgl. [112,117,126]) folgend wird für die Experimente ein einfaches dreilagiges neuronales Netzwerk (ein Multilayer-Perceptron) mit einer Eingabeschicht aus mehreren Neuronen, einer verborgenen Schicht mit mehreren Neuronen und einer Ausgabeschicht, bestehend aus einem Ausgabewert, implementiert.

Für die Wahl der Input-Variablen werden in den Experimenten verschiedene Variationen getestet. Diese sowie die Vorverarbeitung der Daten werden in dem kommenden Abschnitt 4.3.4 erläutert. Die verdeckte Schicht hat 10 Neuronen. Die Gewichte werden durch Backpropagation bestimmt. Das Training wird nach 1000 Iterationen gestoppt. Implementiert wird das Modell unter Verwendung der Python-Bibliothek Pybrain [131].

Da die Berechnung der Gewichte für neuronale Netze sehr rechen- und zeitaufwendig ist, wurde dieses Verfahren nicht für alle 165 Datenreihen evaluiert. Die Analyse beschränkt sich auf den REDD-Datensatz und die REFIT-Datensätze in verschiedenen Aggregationsstufen.

4.3.3.4 K-Nächste-Nachbarn-Regression

Bei dem K-Nächste-Nachbarn-Verfahren (*KNN*) handelt sich um ein nicht-parametrisches Modell, das heißt, es wird weder angenommen, dass ein Modell auf den gesamten Eingaberaum zutrifft, noch werden parametrische Modelle für Unterräume zugrunde gelegt. Es wird lediglich angenommen, dass „ähnliche Eingaben auch ähnliche Ausgaben haben“ (vgl. [110]). Bei einer KNN-Regression werden zur Bestimmung eines y -Wertes für ein Element \mathbf{x} des Eingaberaumes die „nächsten Nachbarn“ innerhalb der Trainingsmenge betrachtet und der y -Wert als – möglicherweise gewichteter – Durchschnitt der zugeordneten y -Werte geschätzt. Als nächste Nachbarn werden diejenigen \mathbf{x}_i aus der Trainingsmenge bezeichnet, welche den geringsten Abstand zu dem \mathbf{x} haben. Dabei sind verschiedene Abstandsmaße umsetzbar. Ein Standardmaß ist der euklidischer Abstand. In der Berechnung des Durchschnitts werden die Nachbarn oft antiproportional zu ihrem Abstand zu \mathbf{x} gewertet.

Ein wesentlicher Vorteil gegenüber vielen parametrischen Verfahren liegt darin, dass kein lineares Modell für den grundlegenden Datensatz existieren muss. Die Schätzung führt zu guten Ergebnissen, solange kleine Veränderungen in \mathbf{x} zu kleinen Veränderungen in y führen, die Trainingsmenge umfassend genug ist und eine geeignete Anzahl k an Nachbarn gewählt wird. Nachteile des Verfahrens begründen sich darin, dass keine Abschätzungen zum Fehler angegeben werden können. Zudem müssen die kompletten Trainingsdaten vorbehalten werden, während bei einem pa-

parametrischen Modell nach einer einmaligen Berechnung der Parameter, die Daten für die weitere Kalkulation nicht weiter benötigt werden.

Die Methode wurde – soweit bekannt – noch nicht für STLF verwendet. Sie ähnelt den Cluster-basierenden Ansätzen in [114, 115], in welchen ebenfalls ein Durchschnitt von ähnlichen \mathbf{x} -Werten zur Ermittlung des Schätzers verwendet wird. Der wesentliche Unterschied liegt darin, dass für die hier betrachtete Methode die k nächsten Nachbarn und nicht die Elemente eines Clusters gewichtet werden.

Die Methode wird unter Verwendung von Scikit-learn in Python für maschinelle Lernmethoden [132] implementiert. Es werden 64 Nachbarn zur Ermittlung des Schätzers verwendet und die Nachbarn durch den Kehrwert der euklidischen Distanz gewichtet. Bei der Anzahl der Nachbarn handelt es sich um einen geschätzten Wert, der sich in der vorherigen Analyse [102] von STLF-Methoden für stündliche Stromlastprognosen als geeignet erwiesen hat. Für die Gewichtung ist es von Bedeutung, dass die Werte der Input-Variablen in einer ähnlichen Größenordnung vorliegen, so dass der Einfluss der Variablen in gleicher Weise berücksichtigt werden kann. Die Standardisierung der Input-Variablen wird in Abschnitt 4.3.4 vorgestellt.

4.3.3.5 Regressionsbäume

Bei Regressionsbäumen (RB) handelt es sich ebenfalls um ein nicht-parametrische Modell. Der Schätzer wird hierbei durch ein hierarchisches System von Entscheidungsregeln festgelegt und als Entscheidungs-, bzw. Regressionsbaum dargestellt. Ein Regressionsbaum beginnt mit einem Wurzelknoten, der sich verzweigt und zu weiteren inneren Knoten mit weiteren möglichen Verzweigungen führt, welche rekursiv zu weiteren Knoten mit Verzweigungen führen können. Jede Verästelung endet in einem sogenannten Blattknoten. Jeder Entscheidungsknoten des Regressionsbaumes repräsentiert eine logische Regel, die abhängig von dem Eingabewert \mathbf{x} entschieden wird. Der durch einen Eingabewert erreichte Blattknoten stellt den Ausgabewert dar. Die graphische Darstellung eines Regressionbaums ist in Abb. 4.12 gegeben.

Der Aufbau eines Regressionsbaumes wird durch folgenden Greedy-Algorithmus auf der Trainingsmenge berechnet: Beginnend bei dem Wurzelknoten wird ein Entscheidungskriterium bestimmt, welches für diesen Schritt die beste Aufteilung – hinsichtlich festgelegter Kriterien – verspricht. Dadurch werden die Daten in disjunkte Mengen aufgeteilt, wobei jeder dieser Mengen ein neuer Knoten mit einem vorläufigen Ausgabewert zugeordnet wird. Sukzessiv wird diese Aufteilung für die neu entstandenen Knoten fortgesetzt, bis die Aufteilung festgelegten Güte-Kriterien auf der Trainingsmenge genügt. Die folgende Beschreibung des Algorithmus zur Aufteilung eines Knotens orientiert sich an der Darstellung in [110].

Sei $\mathcal{D} \in \mathbb{R}^k$ der Raum der möglichen Eingabewerte \mathbf{x} und $\mathcal{X} := \{\mathbf{x}_s\}_{s \in S} \subset \mathcal{D}$ die Menge der \mathbf{x} -Werte in der Trainingsmenge, auf welcher der Baum aufgebaut wird. Sei m ein bereits vorhandener Knoten dieses Baumes und $\mathcal{D}_m \subset \mathcal{D}$ die Menge an möglichen Eingabewerten, für welche dieser Knoten gemäß der vorherigen Entscheidungen den Knoten m erreicht wird. Es wird die Indikatorfunktion $b_m(\cdot)$ definiert,




Abbildung 4.12: Beispiel für einen zweistufigen Regressionsbaum

welche angibt, ob ein \mathbf{x} in \mathcal{D}_m liegt:

$$b_m(\mathbf{x}) = \begin{cases} 1, & \text{falls } \mathbf{x} \in \mathcal{D}_m, \\ 0, & \text{sonst.} \end{cases} \quad (4.11)$$

Als vorläufiger Ausgabewert des Knotens m wird der Mittelwert der y -Werte aus den Trainingsdaten verwendet, für welche der zugehörige \mathbf{x} -Wert in \mathcal{D}_m liegt:

$$g_m := \frac{\sum_{s \in S} b_m(\mathbf{x}_s) y_s}{\sum_{s \in S} b_m(\mathbf{x}_s)}. \quad (4.12)$$

Der mittlere quadratische Fehler an dem Knoten m ist dann

$$MSE_m = \frac{1}{N_m} \sum_{s \in S} (y_s - g_m)^2 b_m(\mathbf{x}_s),$$

wobei $N_m = \sum_s b_m(\mathbf{x}_s)$ die Anzahl der Elemente aus der Trainingsmenge \mathcal{X} beschreibt, welche den Knoten m erreichen. Wenn dieser Fehler kleiner oder gleich einem festgelegten Toleranzwert ε ist, so wird keine weitere Aufteilung vorgenommen und der Knoten als Blattknoten mit dem Wert g_m gespeichert.

Überschreitet der Fehler einen festgelegten Toleranzwert ε , dann wird die Menge \mathcal{D}_m so unterteilt, dass die Summe der Fehler in den Untermengen auf der Trainingsmenge minimal wird: Sei $\cup_{j=1}^l \mathcal{D}_{m,j} = \mathcal{D}_m$ eine mögliche Unterteilung von \mathcal{D}_m in disjunkte Teilmengen. Für jede der Teilmengen $\mathcal{D}_{m,j}$ beschreibe $b_{m,j}(\cdot)$ analog zu (4.11) eine Indikatorfunktion, welche angibt, ob ein \mathbf{x} in $\mathcal{D}_{m,j}$ liegt. Für jede der Teilmengen $\mathcal{D}_{m,j}$ wird ein vorläufiger Ausgabewert $g_{m,j}$ analog zu (4.12) bestimmt.

Der Fehler der Aufteilung berechnet sich dann als:

$$MSE'_m = \frac{1}{N_m} \sum_{j=1}^l \sum_{s \in S} (y_s - g_{m,j})^2 b_{m,j}(\mathbf{x}_s). \quad (4.13)$$

Es wird nach der Aufteilung gesucht, für welche (4.13) minimal wird. Für die Teilmengen der besten Aufteilung werden neue Knoten generiert.

Bei RB besteht eine hohe Gefahr der Überanpassung, daher wird die Anzahl der Verzweigungen häufig durch sogenannte *Pruning*-Verfahren beschränkt: Es werden vorab Kriterien festgelegt, welche die möglichen Aufteilungen an einem Knoten erfüllen müssen, so kann beispielsweise eine Minimalanzahl an Samples festgelegt werden, welche einen Knoten erreichen muss, um zu verhindern, dass Entscheidungsknoten implementiert werden, die nur auf wenigen Trainingsbeispielen basieren. Zudem können nachträglich wenig relevante Unterbäume entfernt werden. Dies wird als *Postpruning* bezeichnet.

Entscheidungsbäume werden hauptsächlich als Entscheidungsunterstützungssysteme verwenden. Als Regressionsverfahren werden sie auch zur Prognose verwendet. Ein wesentlicher Vorteil der Entscheidungs- und Regressionsbäume liegt darin, dass sie ein einfaches, leicht interpretierbares nicht-lineares Modell darstellen. Die Daten müssen nicht vorab verarbeitet werden und die Erstellung der Bäume geht relativ schnell, so dass die Verfahren auch auf großen Datensätzen angewandt werden können. Insbesondere als Maßstab für komplexere Methoden sind sie ein gutes Vergleichsmodell. Allerdings ist die Problemstellung den optimalen Baum zu finden NP-vollständig (vgl. [133]). Der vorgestellte Algorithmus sucht heuristisch lokale Optima, die nicht zwangsläufig zu einem globalem Optimum führen.

In der Literaturrecherche wurde noch keine Anwendung von RB für STLF für Wohngebäude gefunden. Dabei könnten sich die Verfahren sehr gut eignen um nicht-lineare Benutzermuster zu erfassen. Der Lernalgorithmus des Modells wird wie zuvor durch die Anwendung von Scikit-learn in Python implementiert. Dabei werden folgende Einstellung gewählt. Die maximale Tiefe des Baums wird auf 6 festgelegt. Die minimale Anzahl von Samples, die erforderlich sind, um an einem Blattknoten zu sein, wird ebenfalls auf 6 gesetzt. Die minimale Anzahl von Samples, die zum Teilen eines internen Knotens erforderlich sind, wird auf 20 gesetzt. Für den kurzen REDD-Datensatz wird eine geringere Mindestanzahl von 10 Samples evaluiert.

4.3.3.6 Random Forest

Bei der Random Forest Regression (*RF*) wird ein Ensemble von Regressionsbäumen, die für zufällige Untermengen von \mathcal{X} generiert werden, betrachtet. Zur Schätzung des Ausgabewertes für ein $\mathbf{x} \in \mathcal{D}$, wird der \mathbf{x} -Wert für jeden RB des Ensembles ausgewertet und der Mittelwert der erreichten y -Werte als Schätzer verwendet. Eine graphische Darstellung eines Random Forests ist in Abb. 4.13 gegeben.

Durch die Verwendung eines Ensembles ist das Verfahren robuster als RB, da die Varianzen der einzelnen Ausgabewerte reduziert werden. Da die Bäume des Ensem-

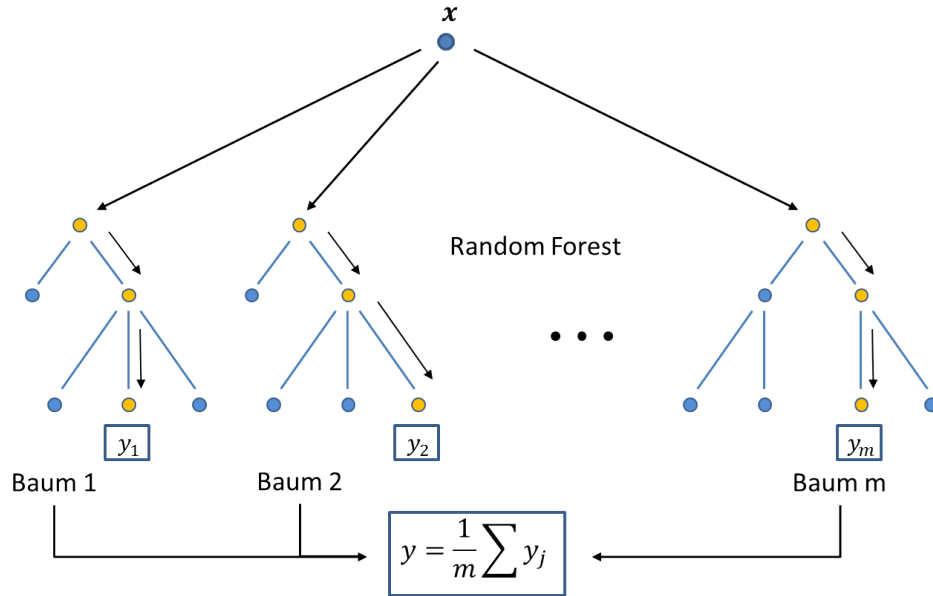


Abbildung 4.13: Konzept einer Random Forest Regression mit m Regressionsbäumen, die Bestimmung des Schätzwerts y erfolgt durch die Mittelwertbildung der erreichten y -Werte.

bles jeweils auf zufälligen (nicht notwendigerweise disjunkten) Untermengen von \mathcal{X} erstellt werden, wird zudem eine Überanpassung vermieden. Das Verfahren gehört zu den schnellen Klassifikations- und Regressionsverfahren auf hoch-dimensionalen Datenmengen (vgl. [134]). Der Rechenaufwand steigt mit der Anzahl von Bäumen, die in dem Ensemble verwendet werden, allerdings werden die Bäume nur auf Untermengen der ursprünglichen Trainingsmenge generiert und die Berechnung der Bäume sowie die Berechnung der Schätzungen können parallelisiert werden. Ein Nachteil des Verfahrens liegt darin, dass Random Forests eine Art Black Box darstellen, sie können nicht wie einzelne Regressionsbäume interpretiert werden.

Auch RF sind soweit bekannt bisher noch nicht für STLF für Wohngebäude eingesetzt worden. Die Methode wird ebenfalls unter der Verwendung von Scikit-learn implementiert. Die Anzahl der Bäume in einem Ensemble wird auf 40 gesetzt. Die maximale Tiefe des Baumes sind wie zuvor 6 Verzweigungen und die minimale Anzahl von Samples, die für eine Aufteilung erforderlich sind, wird weiterhin auf 20 festgesetzt. Eine Ausnahme ist wie zuvor der REDD-Datensatz, für den die Minimalanzahl für eine Aufteilung auf 10 gesetzt wird.

4.3.3.7 Einfache Vergleichsmethoden

Zum Vergleich der genannten Methoden werden zusätzlich zwei sehr einfache Prognoseverfahren implementiert. Es wird zum einen der durchschnittliche Lastgang auf den Trainingsdaten berechnet und zur Prognose verwendet. Diese Methode wird im Weiteren mit *AVG* für „Average“ referenziert. Zum anderen werden persistente Pro-

gnosen (*PER*) evaluiert, bei welchen angenommen wird, dass der Stromverbrauch des zu prognostizierenden Zeitintervalls dem Stromverbrauch des letzten bekannten Zeitintervalls entspricht.

4.3.4 Input-Variablen

Für alle Verfahren außer den AR-Modellen muss noch spezifiziert werden, welche Input-Variablen für die Prognosen verwendet werden. Dies können sowohl vergangene Zeitreihenwerte als auch exogene Variablen sein. Im Folgenden wird eine Auswahl an Input-Variablen vorgestellt, mit welchen die Prognosen evaluiert werden. Für den Prognosehorizont von $h = 1$ werden für jedes Modell (außer ANN) auf jedem Datensatz 24 Variationen der Input-Variablen mit jeweils zwei unterschiedlichen Größen der Trainingsmenge evaluiert, um Aufschluss über eine geeignete Parameterwahl zu bekommen. Für jedes Modell und für jede Datenreihe werden bei $h = 1$ die Input-Variablen bestimmt, welche für eine der Kennzahlen zu dem kleinsten Fehler führen. Diese werden dann für die Prognosen mit einem Zeithorizont von $h = 4, 8, 16, 48$ verwendet. Dabei werden sie ggf. leicht adaptiert, wenn die verwendeten Input-Variablen zu dem Zeitpunkt noch nicht bekannt sind. Für ANN wird die Auswahl der Input-Variablen eingeschränkt, da die Auswertung sonst zeitlich nicht umsetzbar gewesen wäre. Die für ANN evaluierten Input-Variablen werden jeweils explizit genannt.

Da es zudem für einige Methoden notwendig ist, die Input-Variablen in geeigneter Form zu normalisieren, wird zunächst die durchgeführte Transformation der Zeitreihenwerte beschrieben.

4.3.4.1 Datentransformation

Für neuronale Netze ist es vorteilhaft, wenn die Eingabedaten in dem Intervall $[0, 1]$ liegen. Bei den k -nächsten Nachbarn werden die lokalen Nachbarn durch die euklidische Distanz bestimmt. Deshalb ist es wichtig, dass die Input-Variablen ungefähr dieselbe Größenordnung haben, da sonst evtl. nur eine Variable ausschlaggebend für die Bestimmung des Prognosewertes ist. Daher werden alle Zeitreihendaten sowie die Werte der exogenen Variablen so transformiert, dass sie (voraussichtlich) in dem Intervall $[0, 1]$ liegen. Dafür wird die Zeitreihe $\{Y_t\}$ durch den maximalen Wert der Zeitreihe in der ersten Trainingsmenge geteilt und mit 0.9 multipliziert:

$$Y'_t = 0.9 \frac{Y_t}{\max_{s \in S_1} Y_s} \quad \forall t \in T.$$

Auf diese Weise liegen die im ersten Training verwendeten Zeitreihenwerte $Y_s, s \in S_1$ in dem Intervall $[0, 0.9]$. Dabei bezeichnet S_1 die erste Trainingsmenge der Sliding Window Strategie (s. Abschnitt 4.3.2) und umfasst mind. 91 Tage für die CER- und REFIT-Datensätze. Somit sind keine größeren Abweichungen zu erwarten. Wird im Folgenden von den Zeitreihenwerten Y_t gesprochen, so ist die transformierte Zeitreihe Y'_t gemeint. Die Werte der exogenen Variablen werden auf ähnliche Weise transfor-

miert (s. Absatz 4.3.4.3). In den AR-Modellen wird auf diese Datentransformation verzichtet.

4.3.4.2 Zeitreihenwerte

Autokorrelierte Zeitreihenwerte Für die Auswahl von Zeitreihenwerten als Input-Variablen werden nochmals die partiellen Autokorrelationsfunktionen der Zeitreihen, dargestellt in den Abb. 4.7, 4.8 und 4.9, betrachtet. Insbesondere für $h = 1$ liegt bei allen Zeitreihen eine hohe partielle Autokorrelation vor. Zudem besteht ein Zusammenhang zu den Zeitreihenwerten, welche ungefähr einen Tag oder zwei Tage zurückliegen. In der Prognose werden daher Zeitreihenwerte verwendet, die entweder direkt vorangehen oder die ca. 48 halbe Stunden oder eine Woche zurückliegen:

Sei $t + 1$ ein Zeitintervall, für welches eine halbe Stunde im Voraus eine Stromlastprognose erstellt werden soll. Dazu seien die vorausgehenden Verbrauchswerte für alle Zeitintervalle $s \leq t$ bekannt. Dann werden folgende Kombinationen von vergangenen Zeitreihenwerten als Input-Variablen evaluiert: $\{Y_t, Y_{t-1}\}$, $\{Y_t, Y_{t-47}\}$, $\{Y_t, Y_{t-1}, Y_{t-47}, Y_{t-48}\}$ and $\{Y_t, Y_{t-1}, Y_{t-47}, Y_{t-335}\}$. Für neuronale Netze wird die Auswahl aufgrund des Rechenaufwandes auf die Kombinationen $\{Y_t, Y_{t-1}\}$ und $\{Y_t, Y_{t-1}, Y_{t-47}, Y_{t-335}\}$ beschränkt.

Für die Prognosen mehr als eine halbe Stunde im Voraus werden ausgehend von der besten Wahl für $h = 1$, die Zeitreihenwerte so verschoben, dass sie entweder die letzten bekannten Zeitreihenwerte enthalten oder die Zeitreihenwerte, die ein Vielfaches von 48 Zeiteinheiten vor $t + h$ liegen. Die obigen Kombinationen werden für $h \in \{4, 8, 16\}$ zu: $\{Y_t, Y_{t-1}\}$, $\{Y_t, Y_{t+h-48}\}$, $\{Y_t, Y_{t-1}, Y_{t+h-48}, Y_{t+h-49}\}$ and $\{Y_t, Y_{t-1}, Y_{t+h-48}, Y_{t+h-336}\}$; für $h = 48$ zu: $\{Y_t, Y_{t-1}\}$, $\{Y_t, Y_{t-48}\}$, $\{Y_t, Y_{t-1}, Y_{t-48}, Y_{t-49}\}$ and $\{Y_t, Y_{t-1}, Y_{t-48}, Y_{t-336}\}$. Je größer h ist, desto stärker nimmt die Korrelation zu den letzten bekannten Werten im Vergleich zu den Zeitreihenwerten ab, die ein Vielfaches von 48 Zeiteinheiten vor $t + h$ liegen. Daher wird die jeweils letzte Kombination an Input-Variablen auch evaluiert, wenn dies nicht der besten Wahl für $h = 1$ entspricht.

Gleitender Durchschnitt Aus den vorausgehenden Zeitreihenwerten wird zudem der gleitende Durchschnitt (moving average) der letzten Woche berechnet:

$$m_{336,t} = \frac{1}{336} \sum_{h=0}^{335} Y_{t-h}.$$

Mit dieser Variablen können ausgedehnte saisonale Schwankungen erfasst werden. Die Prognosen werden jeweils einmal mit und einmal ohne diese Variable evaluiert.

4.3.4.3 Exogene Variablen

Tageszeit Viele energieintensive Aktivitäten hängen von der Tageszeit ab. Dazu gehört beispielsweise Kochaktivitäten, die Verwendung von digitalen Geräten und

teilweise auch der Betrieb der Waschmaschine. Daher wird eine Input-Variable erstellt, die angibt, in welchem Zeitintervall des Tages ein Zeitreihenwert Y_t liegt. Die Variable nimmt zunächst Werte zwischen 1 und 48 an und wird daher mit einer Division durch 48 normalisiert, so dass die Werte ebenfalls im Intervall $[0, 1]$ liegen.

In der linearen Regressionen wird auf diese Input-Variable verzichtet, da für jedes Zeitintervall des Tages ein eigenes LR-Modell implementiert wird.

Wochentag Um Verbrauchsmuster zu erfassen, die spezifisch für einen bestimmten Wochentag sind, wird getestet, ob es hilfreich ist, die Angabe zum Wochentag ebenfalls als Input-Variable zu modellieren. Dafür werden drei Variationen getestet:

1. Es wird zwischen allen Wochentagen unterschieden: Es wird eine Input-Variable modelliert, welche die Werte 0 für Samstag, $1/7$ für Sonntag, \dots , $6/7$ für Freitag annimmt.
2. Es wird zwischen den Tagen des Wochenendes und Werktagen unterschieden: Es wird eine Input-Variable modelliert, welche für Samstag den Wert 0, für Sonntage den Wert $1/4$, für Montage den Wert $2/4$ und die restlichen Wochentagen den Wert $3/4$ annimmt. Der Montag erhält einen anderen Wert als die weiteren Wochentage, da durch die anderen Input-Variablen ein Zusammenhang zu Zeitreihenwerten des Sonntags aufgestellt werden sollen.
3. Es wird keine Unterscheidung zwischen den Wochentagen gemacht. Es wird keine Input-Variable hierzu modelliert.

Für die neuronalen Netze wird nur die zweite Variation evaluiert. In der linearen Regression wird die Information über den Wochentag nicht als Variable modelliert, sondern stattdessen entweder: (1) für jeden Tag ein eigenes LR-Modell, (2) für Samstag, Sonntag und Montag jeweils ein eigenes Modell und eines für alle weiteren Tage oder (3) ein Modell für alle Tage erstellt.

4.3.5 Kennzahlen

Eine der beliebtesten Kennzahlen zur Bewertung von Prognosen ist der Mean Average Percentage Error (MAPE). Er ist definiert als der durchschnittliche prozentuale Fehler:

$$MAPE := \frac{1}{n} \sum_{t=1}^n \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right|,$$

wobei Y_t der tatsächliche Wert zum Zeitpunkt t ist und \hat{Y}_t den prognostizierten Wert für das Zeitintervall t angibt. Angewandt auf STLF für Wohngebäude, hat der MAPE einen entscheidenden Nachteil: Für Zeiten, in denen der Verbrauch nahe Null ist, wird der MAPE schon durch geringe absolute Fehler sehr groß. Daher wird in der Auswertung ebenfalls der normalisierte durchschnittliche absolute Fehler (engl.

normalized mean absolute error - kurz NMAE) betrachtet:

$$NMAE := \frac{\sum_{t=1}^n |Y_t - \hat{Y}_t|}{\sum_{t=1}^n |Y_t|}.$$

Außerdem wird der normalized root mean square error (NRMSE) berechnet. Er entspricht der Standardabweichung der prognostizierten Werte von den tatsächlichen Werten. Er ist definiert als

$$NRMSE := \sqrt{\frac{\sum_{t=1}^n (Y_t - \hat{Y}_t)^2}{\sum_{t=1}^n Y_t^2}}.$$

Für die Datensätze, in welchen Prognosen für mehrere individuelle Haushalte betrachtet werden, wird jeweils der Durchschnitt dieser Kennzahlen berechnet. Diese werden als $aMAPE$, $aNMAE$ und $aNRMSE$ referenziert, wobei das a für „average“ steht.

4.4 Ergebnisse und Auswertung

4.4.1 Gesamtübersicht

Für die Auswertung der Experimente wird zunächst eine Gesamtübersicht über die erzielten Prognosegenauigkeiten gegeben. Dafür werden die Kennzahlen für alle Experimente berechnet und jeweils die niedrigsten Kennzahlen einer Methode auf einem Datensatz für die Prognosehorizonte von einer halben Stunde, 4 Stunden, 8 Stunden oder 24 Stunden in den Tabellen 4.4, 4.5 und 4.6 dargestellt. Für die Datensätze RFT_1 , CER_1 , RFT_3 , CER_3 , CER_{10} , CER_{30} , welche mehrere Datenreihen enthalten, wird jeweils der Durchschnitt der besten Werte berechnet und präsentiert. In Tab. 4.4 ist der MAPE angegeben, in Tab. 4.5 der NMAE, in in Tab. 4.5 der NMRSE. Jeweils fett markiert sind die besten Werte auf einem Datensatz.

Direkt ins Auge fällt, dass die Fehler mit zunehmenden Aggregationsgrad kleiner werden, dass die Fehler für die Prognose eine halbe Stunde im Voraus am geringsten sind, dass sich die Fehler für die Prognosehorizonte größer als 2 Stunden jedoch nur noch leicht erhöhen und dass die lineare Regression in vielen Settings zu den kleinsten Prognosefehlern führt. Zur differenzierten Analyse der Ergebnisse wird zunächst ein Vergleich der Methoden durchgeführt und im Weiteren die Skalierungseffekte und die Fehlerentwicklung bei steigendem Prognosehorizont untersucht. Im letzten Abschnitt werden die Input-Variablen analysiert.

4.4.2 Vergleich der Methoden

Von den evaluierten Prognosemethoden weist die lineare Regression in vielen Settings die kleinsten durchschnittlichen Prognosefehler auf. Insbesondere für die Datenreihen, welche den Verbrauch von drei oder mehr Haushalten enthalten, sind die Prognosefehler der LR sowohl in Form des MAPE, des NMAE und des NRMSE

Tabelle 4.4: MAPE bzw. aMAPE der Prognoseverfahren für die verschiedenen Datensätzen mit verschiedenen Prognosehorizonten.

	REDD	RFT ₁	CER ₁	RFT ₃	CER ₃	RFT ₁₀	CER ₁₀	CER ₃₀	CER ₁₀₀
halbstündliche Prognose									
SAR	50,8	34,7	58,1	26,0	36,4	17,8	22,5	14,3	8,9
AR ⁺	–	38,4	82,3	26,2	39,9	17,0	22,1	13,5	8,3
LR	88,6	32,5	52,1	25,1	34,6	17,3	20,8	12,3	7,0
ANN	56,2	41,4	–	28,5	–	19,3	–	–	–
KNN	60,4	35,7	67,8	25,7	37,7	17,4	21,1	12,5	7,3
RB	62,7	38,4	70,6	27,0	39,2	18,0	22,3	13,7	8,7
RF	64,9	38,2	70,3	26,7	38,5	17,4	21,8	13,1	8,1
PER	67,2	37,7	66,5	27,5	40,3	18,5	24,9	16,5	11,5
AVG	119,1	62,7	111,4	39,8	51,3	25,3	28,3	18,8	14,7
Prognose 2 Stunden im Voraus									
SAR	110,5	44,8	71,9	34,1	46,2	24,8	30,2	21,0	14,9
AR ⁺	–	49,7	109,5	33,4	50,5	22,4	27,9	18,1	13,4
LR	113,7	45,0	71,5	33,9	44,4	22,3	24,4	14,4	8,5
ANN	80,4	65,4	–	41,2	–	26,8	–	–	–
KNN	81,3	52,1	97,0	34,4	46,7	22,6	24,7	14,5	8,6
RB	108,7	54,8	103,0	36,4	48,1	22,9	25,9	15,9	10,0
RF	97,5	55,4	99,8	36,0	47,3	22,5	25,4	15,4	9,9
PER	97,0	70,5	145,5	49,2	81,9	36,4	55,8	45,1	41,9
Prognose 4 Stunden im Voraus									
SAR	116,3	45,3	71,0	35,1	46,7	26,4	31,7	22,7	15,7
AR ⁺	–	51,8	112,1	35,2	51,4	24,0	28,7	19,1	15,5
LR	116,4	48,5	77,7	35,8	46,1	23,2	24,8	14,5	8,5
ANN	103,7	66,8	–	41,4	–	27,1	–	–	–
KNN	87,3	55,2	99,9	36,0	47,1	23,5	25,0	14,8	8,8
RB	109,5	58,3	103,2	37,6	47,8	23,6	26,0	16,3	10,1
RF	100,7	58,2	102,3	37,4	47,5	23,0	25,5	15,5	9,9
Prognose 8 Stunden im Voraus									
SAR	120,1	45,4	70,4	35,3	46,4	26,8	31,8	22,8	15,7
AR ⁺	–	52,4	112,6	36,4	51,6	24,7	28,7	19,2	15,5
LR	131,8	49,9	81,1	36,5	46,4	23,6	25,0	14,5	8,6
ANN	91,6	68,3	–	43,2	–	26,2	–	–	–
KNN	104,7	57,9	101,1	37,9	47,2	24,5	25,0	14,7	8,8
RB	114,7	60,1	103,7	38,7	47,8	24,1	25,9	16,1	10,1
RF	99,2	60,4	102,8	38,4	47,5	23,3	25,5	15,5	9,9
Prognose 24 Stunden im Voraus									
SAR	108,4	46,0	70,5	35,6	46,3	27,0	31,7	22,7	15,6
AR ⁺	–	51,6	111,9	35,6	51,5	23,9	28,6	19,1	14,7
LR	136,5	49,0	73,0	35,9	45,4	23,6	25,0	14,6	8,7
ANN	87,0	65,8	–	40,5	–	25,4	–	–	–
KNN	109,3	60,6	101,8	39,2	47,3	24,5	24,9	14,7	8,7
RB	106,8	61,9	104,1	38,4	48,0	24,1	26,1	16,3	10,4
RF	98,4	61,6	103,5	38,4	47,7	23,6	25,6	15,5	10,1

Tabelle 4.5: NMAE bzw. aNMAE der Prognoseverfahren für die verschiedenen Datensätzen mit verschiedenen Prognosehorizonten.

	REDD	RFT ₁	CER ₁	RFT ₃	CER ₃	RFT ₁₀	CER ₁₀	CER ₃₀	CER ₁₀₀
halbstündliche Prognose									
SAR	50,3	36,5	47,3	28,2	34,3	19,3	21,8	14,0	8,7
AR ⁺	–	36,7	48,9	27,7	33,9	18,4	20,8	13,2	8,1
LR	64,2	35,5	45,6	27,6	32,7	18,5	19,9	12,1	6,9
ANN	56,4	38,1	–	28,6	–	19,5	–	–	–
KNN	51,1	34,2	45,0	26,6	32,7	18,5	20,1	12,3	7,2
RB	54,4	35,9	46,6	27,7	33,8	19,0	21,1	13,4	8,5
RF	52,3	35,3	45,6	27,1	33,0	18,4	20,5	12,8	7,9
PER	60,8	37,7	52,8	30,7	38,3	21,1	24,4	16,1	10,9
AVG	70,3	62,7	58,7	36,9	40,5	24,3	25,7	18,1	14,6
Prognose 2 Stunden im Voraus									
SAR	68,1	47,3	58,8	36,6	43,0	26,1	28,5	19,8	14,3
AR ⁺	–	45,4	58,7	34,5	40,6	24,2	25,3	17,2	13,1
LR	84,0	45,7	54,6	34,1	38,0	22,5	22,8	14,1	8,4
ANN	63,6	51,1	–	37,6	–	25,5	–	–	–
KNN	61,9	44,3	54,7	33,5	38,1	23,1	23,0	14,2	8,5
RB	77,3	46,0	56,3	34,7	39,0	23,3	23,9	15,4	9,8
RF	65,2	45,5	55,4	34,3	38,4	22,6	23,4	14,8	9,5
PER	85,5	61,0	84,6	49,1	64,1	37,4	46,9	38,1	34,9
Prognose 4 Stunden im Voraus									
SAR	69,3	49,2	60,1	38,2	43,9	27,4	29,6	21,0	14,9
AR ⁺	–	47,2	59,6	36,3	41,1	25,9	25,9	18,2	15,0
LR	85,6	47,3	55,6	35,0	38,5	23,1	23,0	14,1	8,5
ANN	70,0	52,0	–	38,3	–	25,5	–	–	–
KNN	66,0	46,0	55,5	34,8	38,4	23,8	23,2	14,4	8,7
RB	76,4	47,8	56,9	35,7	38,9	23,8	24,0	15,7	9,8
RF	70,3	46,9	55,9	35,1	38,5	23,1	23,4	14,9	9,6
Prognose 8 Stunden im Voraus									
SAR	70,2	49,7	60,4	38,5	44,0	27,7	29,6	21,0	14,9
AR ⁺	–	47,7	59,8	37,1	41,2	26,6	26,0	18,3	15,1
LR	90,6	48,0	55,8	35,4	38,6	23,4	23,1	14,1	8,5
ANN	64,8	52,6	–	38,4	–	24,9	–	–	–
KNN	70,2	47,2	55,8	35,9	38,4	23,9	23,2	14,3	8,6
RB	82,2	48,6	56,9	36,3	39,0	24,0	23,9	15,6	9,8
RF	67,1	47,9	56,0	35,6	38,5	23,3	23,4	14,9	9,6
Prognose 24 Stunden im Voraus									
SAR		49,8	60,2	38,6	43,9	27,7	29,6	20,9	14,8
AR ⁺		47,6	59,7	36,9	41,2	26,3	26,0	18,2	14,7
LR	93,1	48,3	55,7	35,4	38,7	23,5	23,1	14,1	8,6
ANN	65,2	51,3	–	37,5	–	24,8	–	–	–
KNN	69,7	48,5	56,0	36,5	38,4	24,0	23,1	14,3	8,7
RB	72,2	49,5	57,0	36,2	39,1	24,1	24,1	15,8	10,2
RF	65,5	48,6	56,1	35,7	38,6	23,4	23,5	15,0	9,7

Tabelle 4.6: NRMSE bzw. aNRMSE der Prognoseverfahren für die verschiedenen Datensätzen mit verschiedenen Prognosehorizonten.

	REDD	RFT ₁	CER ₁	RFT ₃	CER ₃	RFT ₁₀	CER ₁₀	CER ₃₀	CER ₁₀₀
halbstündliche Prognose									
SAR	68,5	51,6	59,4	39,9	43,0	25,9	26,9	17,2	10,6
AR ⁺	–	49,9	57,1	38,5	41,2	25,0	25,5	16,2	9,9
LR	74,1	49,9	55,9	38,3	40,1	24,5	24,5	15,1	8,6
ANN	69,5	50,7	–	38,6	–	25,2	–	–	–
KNN	66,8	48,1	54,9	37,6	40,1	24,5	24,7	15,3	8,9
RB	73,1	49,5	56,2	38,4	41,1	25,2	26,0	16,5	10,5
RF	67,8	48,2	55,0	37,6	40,3	24,4	25,2	15,9	9,7
PER	78,0	61,3	64,6	47,0	47,5	30,2	30,2	19,5	13,1
AVG	81,8	61,1	68,7	46,4	48,8	31,3	31,2	22,2	17,9
Prognose 2 Stunden im Voraus									
SAR	78,7	63,0	70,6	48,6	52,2	33,9	34,4	23,8	17,8
AR ⁺	–	58,9	64,8	45,6	47,6	31,8	30,7	21,2	16,1
LR	99,8	58,6	62,6	44,3	45,3	29,0	27,9	17,5	10,7
ANN	79,5	60,9	–	46,3	–	31,7	–	–	–
KNN	78,1	57,0	62,2	43,7	45,3	29,9	28,1	17,7	10,8
RB	92,1	58,7	63,5	44,8	46,3	30,2	29,1	19,0	12,3
RF	78,8	57,4	62,5	43,7	45,5	29,4	28,4	18,4	12,1
PER	107,8	82,6	95,4	65,6	73,2	48,0	53,4	43,5	39,8
Prognose 4 Stunden im Voraus									
SAR	80,2	65,8	72,5	50,5	53,8	35,2	35,6	25,0	18,6
AR ⁺	–	61,1	65,4	47,7	48,1	34,1	31,4	22,4	18,2
LR	100,4	59,8	63,1	44,9	45,5	29,6	28,2	17,6	10,8
ANN	83,6	62,2	–	47,0	–	31,7	–	–	–
KNN	85,3	58,5	62,8	44,7	45,5	30,2	28,3	17,9	11,0
RB	93,5	60,2	63,9	45,5	46,2	30,8	29,2	19,4	12,4
RF	85,0	58,8	62,8	44,6	45,6	29,8	28,4	18,4	12,1
Prognose 8 Stunden im Voraus									
SAR	80,6	67,0	73,1	51,2	54,2	35,5	35,7	25,0	18,5
AR ⁺	–	62,1	65,6	48,8	31,5	35,3	31,5	22,5	18,3
LR	103,2	60,3	63,1	45,3	45,6	29,8	28,2	17,5	10,8
ANN	80,4	62,8	–	46,9	–	31,1	–	–	–
KNN	84,3	59,4	62,9	45,5	45,5	30,4	28,2	17,7	10,9
RB	102,1	60,8	63,9	46,1	46,2	31,0	29,1	19,3	12,4
RF	77,4	59,8	62,8	45,0	45,6	29,9	28,4	18,4	12,3
Prognose 24 Stunden im Voraus									
SAR	79,8	67,0	72,9	51,2	54,0	35,5	35,6	24,9	18,4
AR ⁺	–	62,3	65,6	48,9	48,2	35,0	31,5	22,5	18,1
LR	109,0	61,2	63,3	45,4	45,7	30,0	28,2	17,5	10,9
ANN	82,9	62,1	–	46,9	–	31,4	–	–	–
KNN	84,6	60,6	63,1	46,6	45,6	30,6	28,2	17,8	11,1
RB	85,2	61,8	63,9	46,2	46,3	31,1	29,4	19,5	12,7
RF	82,9	60,3	62,9	45,3	45,6	30,2	28,5	18,5	12,3

von den evaluierten Verfahren am niedrigsten. Für die Verbrauchsprognosen für die Zeitreihen der einzelnen Haushalte sind die Ergebnisse nicht so eindeutig: Für die Datenreihen der einzelnen Haushalten aus REFIT und CER erreicht SAR den kleinsten MAPE bei einem Prognosehorizont von mehr als zwei Stunden. Allerdings hat SAR einen deutlich schlechteren NMAE und NRMSE als LR. Der niedrigste NMAE für die Lastprognosen einzelner Haushalte wird in den meisten Fällen durch das k-nächste-Nachbarn-Verfahren erreicht. KNN führt zudem zusammen mit Random Forests zu dem niedrigsten NRMSE für Datenreihen von einem bis drei Haushalten. Zudem werden durch KNN auch für Datenreihen mit mehr als drei Haushalten kompetitive Ergebnisse zu LR in allen Kennzahlen erreicht.

Neuronale Netze schneiden nur auf dem kurzen REDD-Datensatz vergleichsweise gut ab. Auf den Datenreihen aus REFIT fällt die Prognosegenauigkeit gegenüber den anderen Methoden deutlich ab. Auch AR^+ bleibt hinter den anderen Methoden zurück: Nur für die Zeitreihen aus REFIT wird in einigen Fällen ein leicht niedrigerer MAPE oder NMAE als bei LR erreicht. Für die anderen Auswertungen und insbesondere für die Evaluationen für die Zeitreihen aus CER sind die Ergebnisse für AR^+ deutlich schlechter. Letzteres kann daran liegen, dass einige Zeitreihen aus CER zusätzlich zu den saisonalen Schwankungen von einem Tag jahreszeitliche Schwankungen aufweisen und diese durch die Modellierung des AR-Modells mit deterministischen Tagesanteilen besonders schlecht abgebildet werden können. Aber auch die stochastische Modellierung der saisonalen Komponenten mit SAR führt nur für die Zeitreihen von drei oder weniger Haushalten zu einem vergleichsweise vorteilhaften MAPE. Die Bewertung von RF hängt stark von der verwendeten Kennzahl ab: Für einzelne Haushalte und die Aggregation von drei Haushalten wird häufig der niedrigste NRMSE erreicht. Dass insbesondere ein guter NRMSE erzielt wird, gehört zu den typischen Eigenschaften einer Ensemble-Methode, da die Varianzen der Ausgabewerte durch die Bildung von Ensembles relativ niedrig gehalten werden. Dabei ist das Verfahren auch bzgl. des NMAE für die Verbrauchsprognosen mit drei oder weniger Haushalten mit weniger als einem Prozent Differenz kompetitiv zur LR. Im MAPE weicht der Fehler mit 6 – 30% Differenz bei den Lastprognosen der einzelnen Haushalte deutlich von den Ergebnissen von LR ab. Das impliziert, dass explizit die niedrigen Verbrauchswerte durch LR besser prognostiziert werden können. Regressionsbäume sind für alle Auswertungen auf den REFIT und CER-Datensätzen zwischen 0,2 – 1,5% schlechter als RF, wobei die größten Differenzen zwischen RB und RF bzgl. des NRMSE vorliegen. Bei den Prognosen auf dem kurzen REDD-Datensatz ist der Unterschied zwischen den Ergebnissen der beiden Methoden nochmals wesentlich größer.

Die Ergebnisse der Vergleichsmethode AVG sind jeweils nur in dem obersten Tabellenabschnitt dargestellt, da die Ergebnisse unabhängig von dem Prognosehorizont sind. Für die Prognose mit einem Prognosehorizont von einer halben Stunde ist AVG noch wesentlich schlechter als alle Methoden und die Differenz zu der Prognosegenauigkeit von LR beträgt zwischen 7 – 30% im MAPE, zwischen 6 – 27% im NMAE und 7 – 13% im NRMSE. Diese Differenz verringert sich im MAPE mit zunehmendem Prognosehorizont von 33% auf 14% für die einzelnen Zeitreihen aus

REFIT und von 59% auf 38% für die einzelnen Zeitreihen aus CER. Auf den Datenreihen, welche den Verbrauch von mehr als drei Haushalten enthalten, reduziert sich der Unterschied des MAPE auf 1,7 – 6%. Auch für den NMAE nimmt die Differenz des Fehlers von LR zu AVG mit zunehmendem Prognosehorizont leicht ab. Dabei ist der Unterschied bei einem Prognosehorizont von 24 Stunden für die Lastprognosen von drei bis zehn Haushalten mit 1,5 – 2,6% am geringsten. Bzgl. des NRMSE sind die Prognosen 24 Stunden im Voraus für RFT₁ mit LR nicht besser als AVG, für die anderen Datenreihen erreicht LR eine Verbesserung von 1 – 7% gegenüber AVG. Der größte Unterschied liegt für CER₁₀₀ vor.

Die zweite einfache Vergleichsmethode hat für die Prognosen mit einem Prognosehorizont von einer halben Stunde schlechtere Ergebnisse als nahezu alle der komplexeren Methoden. Da sich die Genauigkeit mit zunehmendem Prognosehorizont bei PER nochmals drastisch verschlechtert, wurden die Ergebnisse für Prognosehorizonte von mehr als zwei Stunden aus Platzgründen nicht dargestellt.

Es steht außer Frage, dass das Potential der gewählten Methoden in der vorliegenden Analyse noch nicht ausgeschöpft wurde. Es wurden für jede Methode jeweils Standardmodelle implementiert, welche durch Adaptionen noch verbessert werden könnten. Die durchgeführten Experimente geben eine Einschätzung dieser Verfahren im Vergleich und eine Abschätzung, welche Ergebnisse ohne weitere spezifische Anpassungen durchschnittlich erreicht werden. Dabei schneiden insbesondere das LR-Modell und die k-nächsten Nachbarn gut ab, während die anderen Verfahren jeweils nur für einzelne Settings vergleichbare oder bessere Ergebnisse erhalten.

4.4.3 Skalierungseffekte

Die Kennzahlen der Prognosegenauigkeit verbessern sich mit zunehmendem Aggregationsgrad in den Datenreihen. Dies liegt daran, dass die Datenreihen über den Stromverbrauch einzelner Haushalte von den teilweise unberechenbaren Handlungen der Bewohner abhängen. In den Verbrauchsdaten mehrerer Wohnungen mitteln sich die Fehler teilweise weg. Dieser Effekt wirkt sich u.a. auf die Variationskoeffizienten der Datenreihen aus. Auf diesen Effekt wurde bereits in Absatz 4.2.2.2 hingewiesen und in Absatz 4.3.1.1 ist in Tab. 4.3 ein Überblick über die Variationskoeffizienten der verwendeten Datenreihen gegeben.

In diesem Abschnitt wird untersucht, ob ein Zusammenhang zwischen dem Variationskoeffizienten und der Prognosegenauigkeit von Stromlasten besteht. Dafür werden die Ergebnisse des erfolgreichsten Modells, der lineare Regression, auf den Datensätzen REFIT und CER untersucht. Der REDD-Datensatz wird außen vorge lassen, da der Trainingszeitraum als zu kurz angesehen wird. In der Abb. 4.14 sind die Kennzahlen der Prognosen der verbleibenden 164 Zeitreihen bei LR in Abhängigkeit der entsprechenden Variationskoeffizienten dargestellt. Dabei lässt sich ein klarer Zusammenhang erkennen, der sich in einer annähernd logarithmischen Kurve darstellt. Näherungsweise können die Prognosefehler durch folgende Funktionen in

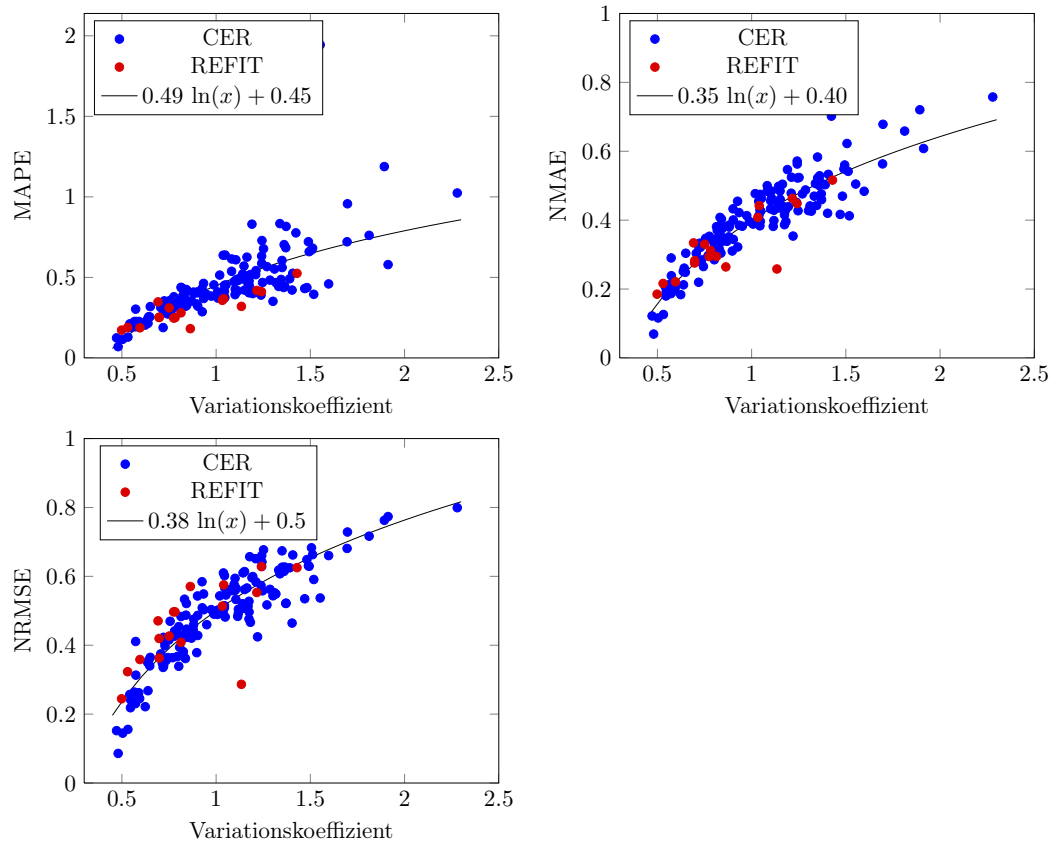


Abbildung 4.14: Zusammenhang zwischen den Kennzahlen MAPE, NMAE und NRMSE der Prognosen mit LR und den Variationskoeffizienten für die Datenreihen aus REFIT und CER.

Abhängigkeit von dem Variationskoeffizienten beschrieben werden:

$$\begin{aligned} g_{\text{MAPE}}(x) &= 0,49 \ln(x) + 0,45, \\ g_{\text{NMAE}}(x) &= 0,35 \ln(x) + 0,40, \\ g_{\text{NRMSE}}(x) &= 0,38 \ln(x) + 0,5. \end{aligned}$$

Dabei ist anzumerken, dass diese Abschätzungen nicht für Variationskoeffizienten kleiner als 0.4 geeignet sind, da die geschätzte Prognosegenauigkeit bzgl. des MAPE, g_{MAPE} , sonst negative Werte annehmen würde. Daher wird der Definitionsbereich auf das Intervall $[0,45; 2,5]$ eingeschränkt. In diesem Intervall befinden sich alle untersuchten Datenreihen und man kann davon ausgehen, dass die Variationskoeffizienten von Datenreihen, welche den Stromverbrauch von Haushalten beschreiben, nicht beliebig klein werden, da die Lastgänge üblicherweise gewisse Bedarfsschwankungen im Laufe des Tages aufweisen. Wertet man standardisierte Lastprofile aus, welche sich aus den durchschnittlichen Verbrauchskurven von Haushalten auf einer Verteilernetzebene ergeben (vgl. [44]), erhält man einen Variationskoeffizienten von

0.4254. Insofern erscheint es zulässig, davon auszugehen, dass die Variationskoeffizienten von Datenreihen zum Stromverbrauch von einzelnen Wohnungen, Wohnblöcken und kleinen Microgrids diesen Wert nicht unterschreiten.

Zur Bewertung dieser Fehlerabschätzungen, wird das Bestimmtheitsmaß

$$R^2 = \frac{\sum_{i=1}^m (g(x) - \bar{y})^2}{\sum_{i=1}^m (y_i - \bar{y})^2},$$

betrachtet, wobei $g(\cdot)$ in diesem Fall die Schätzung des Prognosefehlers darstellt, $m = 164$ die Anzahl der Datenreihen, y_i den tatsächlichen Prognosefehler der entsprechenden Zeitreihe und \bar{y} den durchschnittlichen Prognosefehler beschreibt. Das Bestimmtheitsmaß gibt an, wie gut sich die Variation der Prognosefehler durch das Regressionskurve erklären lässt (vgl. [135]). Nimmt das Bestimmtheitsmaß einen Werte nahe 1 an, sind die Daten nahezu perfekt beschrieben, je niedriger der Wert ist, desto schlechter ist die Anpassung der Daten. Für die Schätzung des MAPE mit g_{MAPE} ist $R^2 = 0,55$; für die Schätzung des NMAE mit g_{NMAE} ist $R^2 = 0,84$ und für die Schätzung des NRMSE mit g_{NRMSE} ist $R^2 = 0,81$. Das heißt, für NMAE und NRMSE können die Prognosefehler für halbstündliche Stromlastprognosen abhängig von dem Variationskoeffizienten näherungsweise abgeschätzt werden. Dieses Wissen ist vorteilhaft, wenn es darum geht, Anwendungen für STLF zu entwickeln, da man abhängig von dem Variationskoeffizienten, welcher sich bereits auf kurzen Zeitreihen berechnet lässt, eine Einschätzung der Prognosefehler erhält.

Auch für einen Prognosehorizont von $h = 4, 8, 16, 48$ halben Stunden im Voraus besteht ein ähnlicher Zusammenhang zwischen den Variationskoeffizienten und der Prognosegenauigkeit des LR-Verfahrens. In Abb. 4.15 sind die Schätzfunktionen für die Kennzahlen für die weiteren evaluierten Prognosehorizonte dargestellt. Dabei wird die Kurve für alle Kennzahlen etwas steiler. Für einen Variationskoeffizienten nahe 0,5 ändern sich die Fehler kaum. Für eine steigende Variabilität fächert sich die Schätzfunktion des MAPE abhängig von dem Prognosehorizont h auf. Für den NMAE und NRMSE sind die Schätzfunktionen für alle $h \geq 4$ jeweils nahezu identisch. Das Bestimmtheitsmaß der Abschätzung erhöht sich für den MAPE auf 0,63, für den NMAE auf 0,89 und für den NRMSE auf 0,85.

Die Abschätzung der Prognosegüte ist eine wichtige Information für die nachfolgende Optimierung, bei welcher die Stromlastprognose zum Einsatz kommt. Der Zusammenhang zwischen der Prognosegüte und dem Variationskoeffizienten, welcher durch die vorliegende Arbeit – soweit bekannt erstmals – erfasst und dargestellt wurde, bietet die Möglichkeit, die Größenordnung der zu erwartenden Fehler abzuschätzen.

4.4.4 Prognosezeitraum

In den Auswertungen der Prognosen in den Tabellen 4.4, 4.5 und 4.6 ist erkennbar, dass die Ergebnisse der Prognosen mit dem kürzesten Prognosehorizont von einer halben Stunde im Voraus die niedrigsten Fehler haben. Die Prognosegenauigkeit nimmt deutlich ab, wenn die Prognose zwei Stunden oder mehr im Voraus erfolgen

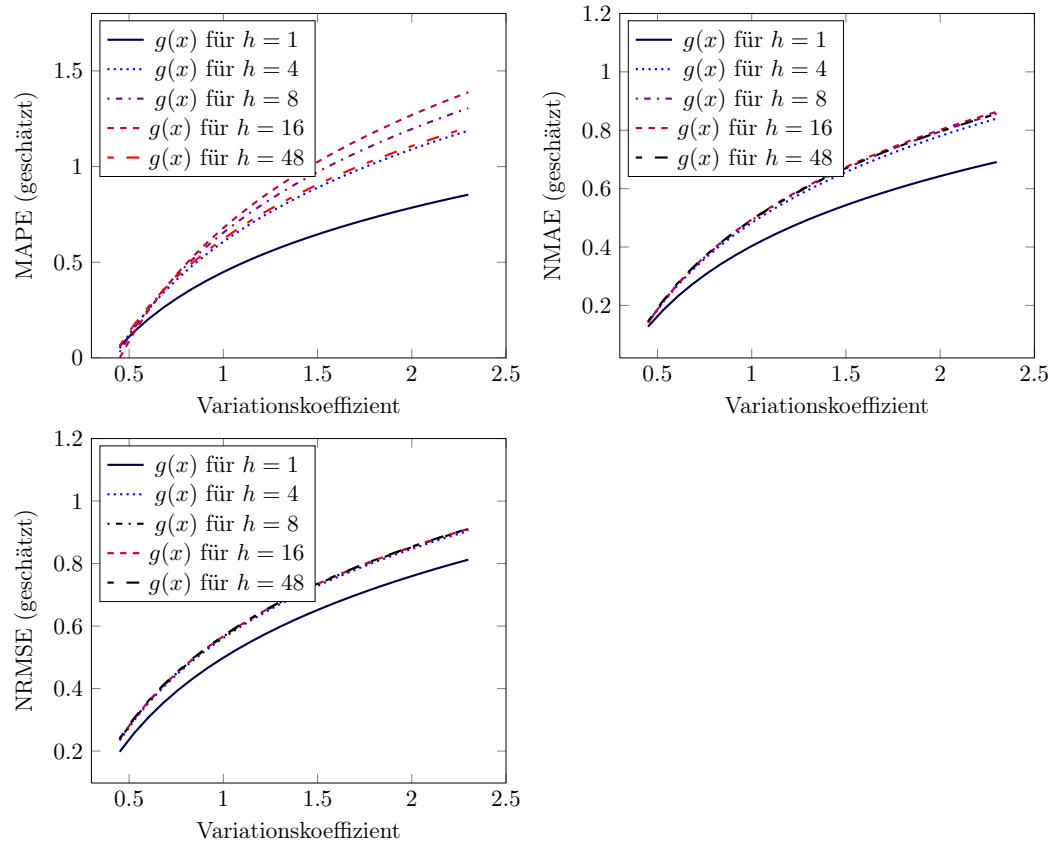


Abbildung 4.15: Schätzfunktionen der Kennzahlen MAPE, NMAE und NRMSE in Abhängigkeit des Variationskoeffizienten für die Prognosehorizonte $h = 1, 4, 8, 16, 48$.

soll. Allerdings scheint die Prognosegenauigkeit ab einem Prognosehorizont von vier Stunden zu konvergieren. Dies gilt für alle Aggregationsstufen der Datenreihen. In der Abb. 4.16 ist die Fehlerentwicklung des MAPE bei LR in Abhängigkeit des Prognosehorizonts und der Anzahl der Haushalte für die REFIT und CER Datensätze graphisch dargestellt. Dabei lässt sich das beschriebene Phänomen gut erkennen. Für die andere Methoden und die anderen Kennzahlen sieht die Darstellung ähnlich aus, wobei der Anstieg des Fehlers von einem Prognosehorizont von einer halben Stunde zu dem Prognosehorizont zwei Stunden im Voraus für den MAPE besonders groß ist. Für die anderen Kennzahlen fällt er etwas kleiner aus.

Man kann davon ausgehen, dass der Einfluss der direkt vorausgehenden Zeitreihenwerte auf das Regressionsmodell bei einem steigenden Prognosehorizont bis vier Stunden im Voraus abnimmt und der Einfluss der anderen Input-Variablen zunimmt. Diese These wird bei der Analyse der Input-Variablen weiter untersucht.

In der Darstellung des MAPE auf den CER-Datensätzen in Abb. 4.16 ist zudem erkennbar, dass der MAPE bei einzelnen Haushalten 24 Stunden im Voraus geringfügig besser ist als acht Stunden im Voraus. Dies ist ein Hinweis darauf, dass die

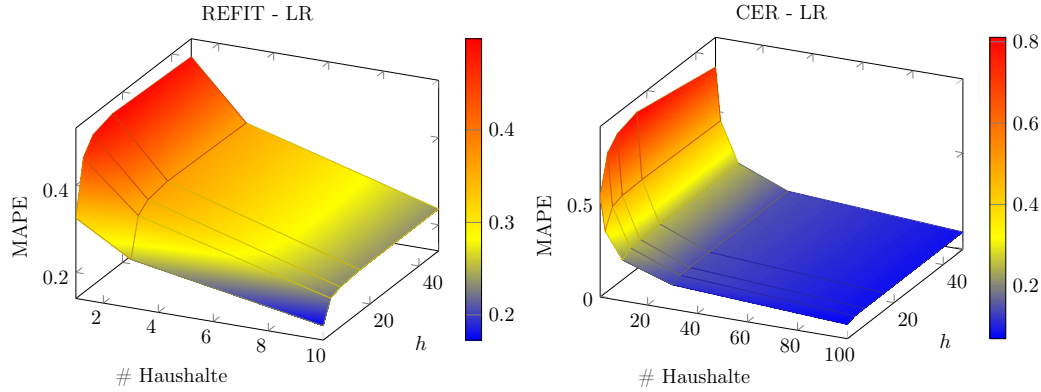


Abbildung 4.16: MAPE, bzw. aMAPE der Prognosen mit LR bei steigendem Prognosehorizont $h = 1, 4, 8, 16, 48$ für die Datenreihen aus REFIT und CER.

Korrelation von Y_t und Y_{t-16} sehr gering ist und für die Prognosen acht Stunden im Voraus andere vorausgehende Zeitreihenwerte in dem Modell betrachtet werden sollten.

4.4.5 Analyse der Input-Variablen

Es wird untersucht, in welchem Modell bei welcher Anzahl von Haushalten welche Input-Variablen zu den besten Kennzahlen in den Experimenten geführt haben. Die beste Wahl kann sich bei jedem Verfahren abhängig von der zugrundeliegende Datenreihe unterscheiden. Da die Prognosen jedoch für eine hohe Anzahl von Datenreihen durchgeführt wurden, wird geprüft, inwiefern sich allgemeine Indikationen für die Wahl der Input-Variablen bei Stromlastprognosen ableiten lassen. Dabei werden die Experimente auf dem REDD-Datensatz nicht berücksichtigt, da die Prognosen aufgrund des kurzen Trainingssatzes kaum aussagekräftig sind. Auch für die neuronalen Netze wird auf die Analyse verzichtet, da nur eine eingeschränkte Auswahl der Input-Variablen analysiert wurde.

Die SAR-Modelle wurden mit $AR(p) \times (1)_{48}$ -Modellen mit $p = 1, 2, 3$ umgesetzt. Dabei führt $AR(1) \times (1)_{48}$ auf 73% der Datenreihen einzelner Haushalte zu dem niedrigsten MAPE, wobei mit $AR(3) \times (1)_{48}$ häufiger ein niedrigerer NMAE und NRMSE erreicht wird. Für den NRSME ist $AR(3) \times (1)_{48}$ in 91% der Fälle das beste der evaluierten SAR-Modelle. Dieses Modell erreicht auch in der Auswertung von [123] die besten Ergebnisse. Bzgl. der Länge des Trainingszeitraums liegt kein eindeutiges Ergebnis vor. Die Ergebnisse finden sich in ähnlicher Ausprägung für die Prognosen der aggregierten Datenreihen wieder. Es ist keine spezifische Verschiebung bei steigendem Prognosehorizont erkennbar.

In dem zweiten AR-Modell, AR^+ , wurden die saisonalen Anteile mit deterministischen Komponenten modelliert und $AR(p)$ -Modelle auf den saisonbereinigten Datenreihen mit $p = 1, 2, 3, 4, 5$ erstellt. Dabei ist für den NRMSE eine Präferenz zu Modellen mit $p \geq 3$ ersichtlich, für die anderen Kennzahlen ist keine klare Präferenz der Ordnung p erkennbar. Die große Trainingsmenge bestehend aus 4/5 der Daten

Tabelle 4.7: Analyse der Input-Variablen für die Stromlastprognosen einzelner Haushalte eine halbe Stunde im Voraus. Es wird dargestellt, wie häufig welche Input-Variablen zu den besten Ergebnisse bzgl. der betreffenden Kennzahl geführt haben.

Kennz.	Meth.	Training		Zeitreihenwerte				Wochentage			MA
		kurz	lang	I	II	III	IV	V1	V2	V3	
MAPE	LR	23%	77%	80%	15%	2%	3%	94%	6%	0%	0%
NMAE	LR	22%	78%	9%	22%	4%	65%	91%	9%	0%	21%
NRMSE	LR	25%	75%	10%	18%	1%	71%	92%	8%	0%	98%
MAPE	KNN	25%	75%	88%	4%	1%	7%	61%	29%	10%	21%
NMAE	KNN	25%	75%	82%	4%	1%	13%	64%	30%	5%	43%
NRMSE	KNN	29%	71%	81%	8%	2%	9%	60%	38%	3%	84%
MAPE	RB	30%	70%	50%	10%	14%	26%	38%	36%	27%	34%
NMAE	RB	25%	75%	54%	12%	13%	21%	35%	38%	27%	28%
NRMSE	RB	21%	79%	46%	24%	9%	21%	33%	30%	37%	25%
MAPE	RF	32%	68%	56%	5%	6%	32%	27%	36%	38%	27%
NMAE	RF	35%	65%	50%	4%	9%	38%	24%	38%	36%	23%
NRMSE	RF	33%	67%	48%	9%	12%	31%	15%	43%	41%	26%

führt bei einer Mehrzahl der Datenreihen zu besseren Ergebnissen als die Modellerstellung mit nur 91 Tagen. Für die aggregierten Datenreihen sind die Ergebnisse ähnlich. Wie zuvor bei den SAR-Modellen ist keine spezifische Verschiebung bei steigendem Prognosehorizont erkennbar.

Bei den anderen Methoden wurden jeweils die gleichen Input-Variablen in den Experimenten evaluiert. Dabei war jeweils eine der folgenden vier Kombinationen von vorausgehenden Zeitreihenwerten Bestandteil der Input-Variablen: (I) $\{Y_t, Y_{t-1}\}$, (II) $\{Y_t, Y_{t-47}\}$, (III) $\{Y_t, Y_{t-1}, Y_{t-47}, Y_{t-48}\}$ und (IV) $\{Y_t, Y_{t-1}, Y_{t-47}, Y_{t-365}\}$. In der Beschreibung der Wochentage wurden drei Variationen evaluiert: (V 1) keine Unterscheidung zwischen den Wochentagen, (V 2) eine Unterscheidung zwischen Werktagen und Wochenende, (V 3) differenzierte Unterscheidung zwischen allen Wochentagen. Zudem wurde der gleitende Wochendurchschnitt (MA) als optionale Input-Variable evaluiert. Die detaillierte Beschreibung der verschiedenen Settings ist in Abschnitt 4.3.4 zu finden. Zur Analyse dieser Settings wird zunächst untersucht, mit welcher Häufigkeit welche Input-Variablen zu den besten Stromlastprognosen für einzelne Haushalte geführt haben. Die Ergebnisse sind in Tab. 4.7 dargestellt. Dabei wird zwischen den verschiedenen Kennzahlen differenziert.

Aus der Aufschlüsselung der bevorzugten Input-Variablen ist ersichtlich, dass die Verwendung des langen Trainingsdatensatzes, welcher 4/5 der gesamten Datenreihe umfasst, bei allen Methoden für die meisten Zeitreihen (65 – 79%) zu besseren Ergebnissen führt als das Training auf dem kurzen Datensatz von 91 Tagen. Die Analyse der Input-Variablen werden für die jeweiligen Methoden einzeln beschrieben. Für LR führen je nach Kennzahl andere vorausgehende Zeitreihenwerte zu den besten Ergebnissen. Für den MAPE ist das in den meisten Fällen $\{Y_t, Y_{t-1}\}$, für den NMAE und den NRMSE ist das $\{Y_t, Y_{t-1}, Y_{t-47}, Y_{t-365}\}$. Für alle Kennzahlen ist es bei LR nicht vorteilhaft, zwischen den Wochentagen zu unterscheiden. Inwiefern die

Tabelle 4.8: Analyse der Input-Variablen für die Stromlastprognosen von 10 aggregierten Haushalten eine halbe Stunde im Voraus. Es wird dargestellt, wie häufig welche Input-Variablen zu den besten Ergebnisse bzgl. der betreffenden Kennzahl geführt haben.

Kennz.	Meth.	Training		Zeitreihenwerte				Wochentage			MA
		kurz	lang	I	II	III	IV	V1	V2	V3	
MAPE	LR	9%	91%	0%	18%	0%	27%	94%	73%	0%	18%
NMAE	LR	9%	91%	0%	9%	0%	91%	64%	36%	0%	100%
NRMSE	LR	9%	91%	0%	9%	0%	91%	73%	27%	0%	100%
MAPE	KNN	18%	82%	55%	27%	1%	18%	18%	73%	9%	64%
NMAE	KNN	9%	91%	36%	55%	0%	9%	18%	82%	0%	73%
NRMSE	KNN	9%	91%	27%	73%	0%	0%	9%	91%	0%	100%
MAPE	RB	27%	73%	36%	9%	9%	45%	27%	64%	9%	27%
NMAE	RB	9%	91%	36%	27%	9%	27%	27%	55%	18%	18%
NRMSE	RB	18%	82%	55%	9%	0%	36%	27%	55%	18%	15%
MAPE	RF	36%	64%	36%	0%	0%	64%	18%	45%	36%	36%
NMAE	RF	36%	64%	27%	0%	0%	73%	27%	18%	55%	27%
NRMSE	RF	27%	73%	27%	9%	0%	64%	9%	45%	45%	64%

Verwendung des gleitenden Wochendurchschnitts zu einer Verbesserung des Modells beiträgt, hängt wiederum von der bewertenden Kennzahl ab; für den NRMSE führt die Aufnahme des gleitenden Wochendurchschnitts als Input-Variable in 98% der Fälle zu einer Verbesserung, während sie für den NMAE in wenigen Fällen (21%) und für den MAPE in keinem Fall zu einer Verbesserung führt.

Für den KNN ist die Auswahl der besten Input-Variablen weniger sensitiv gegenüber der Kennzahl: Für mehr als 80% der Datenreihen werden die besten Ergebnisse mit den direkt vorausgehenden Input-Variablen $\{Y_t, Y_{t-1}\}$ erreicht. Bei ca. 60% wird nicht zwischen den Wochentagen unterschieden, bei ca. 30% führt eine Unterscheidung von Werktagen und Tages des Wochenendes zu besseren Ergebnissen. Die Verwendung des gleitenden Wochendurchschnitts erweist sich bei 84% für den NRMSE vorteilhaft, für die beiden anderen Kennzahlen nicht.

Die Analyse der Input-Variablen für RB weist ebenfalls keine großen Differenzen zwischen den Kennzahlen auf: Wieder werden für alle Kennzahlen die besten Ergebnisse mit den direkt vorausgehenden Input-Variablen $\{Y_t, Y_{t-1}\}$ erreicht. Die drei Variationen zur Beschreibung des Wochentags führen jeweils bei einem Drittel der Datenreihen zu dem besten Ergebnis. Der gleitende Wochendurchschnitt führt bei den meisten Datenreihen zu keinen besseren Ergebnissen.

Bei der Anwendung von RF ist es für einen Großteil (48 – 56%) der Datenreihen vorteilhaft nur die vorangehenden Zeitreihenwerte $\{Y_t, Y_{t-1}\}$ zu nehmen, bei einem weiteren Anteil von mehr als 30% erweist sich die Kombination $\{Y_t, Y_{t-1}, Y_{t-47}, Y_{t-365}\}$ als die beste. Dabei wird bei allen Kennzahlen in über 36% der Fälle zwischen Werktagen und Wochenende und in jeweils über 36% der Fälle zwischen jedem einzelnen Wochentag unterschieden. Der gleitende Wochendurchschnitt erweist sich für die meisten Datenreihen in allen Kennzahlen als nicht vorteilhaft.

Die Auswahl der besten Input-Variablen ändert sich teilweise mit zunehmenden Aggregationsgrad. In Tab. 4.8 sind die prozentualen Häufigkeiten der Input-Variablen dargestellt, mit welchen bei den Stromlastprognosen für den aggregierten Verbrauch von zehn Haushalten die besten Ergebnisse erreicht wurden. Wie bei den Prognosen für den Verbrauch einzelner Haushalte führt die Verwendung des längeren Trainingsdatensatzes in den meisten Fällen zu besseren Ergebnissen als das Training auf dem kürzeren. Der prozentuale Anteil der Datenreihen, für welche der längere Trainingsdatensatz vorteilhaft ist, steigt sogar für alle Methoden außer RF an.

Bei LR nimmt die Bedeutung der Input-Variablen $\{Y_t, Y_{t-1}\}$ ab: bei mehr als 82% der Datenreihen wird für jede Kennzahl die Kombination $\{Y_t, Y_{t-1}, Y_{t-47}, Y_{t-365}\}$ genutzt. Nun führt die Unterscheidung von Werktagen und Tagen des Wochenendes zu einem niedrigeren MAPE und auch für die anderen Kennzahlen steigt der Anteil der Datenreihen, bei welchen diese Unterscheidung vorteilhaft ist. Der gleitende Wochendurchschnitt gewinnt für den NMAE an Bedeutung. Die Änderungen in der Auswahl der besten Input-Variablen sind bei den anderen Methoden ähnlich zu denen in LR: Anstelle der Zeitreihenwerte $\{Y_t, Y_{t-1}\}$ werden für viele Datenreihen Zeitreihenwerte gewählt, die nicht nur von dem direkt vorangehenden Verbrauch abhängen. Bei KNN wird in vielen Fällen $\{Y_t, Y_{t-47}\}$, bei RB und RF $\{Y_t, Y_{t-1}, Y_{t-47}, Y_{t-365}\}$ bevorzugt. Es erweist sich als vorteilhaft, zwischen Wochenende und Werktagen bei den Prognosen zu unterscheiden. Die Nutzung des gleitenden Wochendurchschnitt führt bei KNN für die meisten Datenreihen zu besseren Ergebnissen, bei RB und RF nicht.

Betrachtet man die Ergebnisse der Stromlastprognosen h halbe Stunden im Voraus mit $h = 4, 8, 16, 48$, so nimmt die Bedeutung der Input-Variablen $\{Y_t, Y_{t-1}\}$ ebenfalls ab und es werden auf vielen Datenreihen die besseren Ergebnisse mit $\{Y_t, Y_{t-1}, Y_{t+h-48}, Y_{t+h-336}\}$ erreicht. Dies gilt insbesondere bei den Methoden LR und KNN. Bei RB und RF besteht der Trend ebenfalls, wobei jedoch auch bei 8 Stunden im Voraus in knapp 30% der Fälle die besten Kennzahlen mit $\{Y_t, Y_{t-1}\}$ erzielt werden.

Die durchgeführte Analyse zeigt, dass die geeignete Wahl der Input-Variablen sowohl von der Methode als auch von der zugrundeliegenden Datenreihe und teilweise auch der verwendeten Kennzahl abhängt. Durch Aufschlüsselung der Input-Variablen, welche zu den besten Ergebnissen geführt haben, wurden methodenspezifische Hinweise für die Wahl abgeleitet.

4.5 Diskussion

Die Ergebnisse der Experimente geben eine Übersicht über die Prognosegenauigkeit der verschiedenen Methoden und stellt einen Zusammenhang zwischen dem Variationskoeffizienten und der Prognosegüte auf. Zudem wurde dargestellt, wie sich der Fehler bei steigendem Prognosehorizont entwickelt und aus einer Analyse verschiedener Input-Variablen methodenspezifische Hinweise zur Wahl dieser abge-

leitet. Damit wird die Forschungslücke geschlossen, welche in der Literaturrecherche ausgewiesen wurde. Im Folgenden werden die Limitierungen der Analyse dargestellt und weitergehende Forschungsfragen aufgezeigt.

4.5.1 Limitierungen

Bei den verwendeten Prognoseverfahren handelt es sich jeweils um Standardmodelle. Da für die meisten der verwendeten Verfahren Adaptionen möglich sind, besteht durchaus Potential, die präsentierten Ergebnisse zu verbessern. So ist beispielsweise der Spielraum, der sich bei der Modellierung von neuronalen Netzen durch die Kombinationsmöglichkeiten verschiedener Topologien, Berechnungselemente und Algorithmen ergibt, immens. Auch für Regressionsbäume und Random Forests ergibt sich ein erheblicher Spielraum durch die Wahl der Hyperparameter. In der vorliegenden Analyse wurden sie auf der Basis einer vorherigen Studie geschätzt. Bei den AR-Modellen wurden die Ordnungen der Modelle auf Basis einer heuristischen Analyse der empirischen Autokorrelationen geschätzt und eine Auswahl umgesetzt. Ein weiteres Potential zur Verbesserung der Prognosegüte liegt in der Kombination verschiedener Verfahren, wie es beispielsweise in [113] vorgeschlagen wird.

In diesem Sinne erhebt die Studie nicht den Anspruch, das bestmögliche Prognoseverfahren implementiert zu haben, sondern bietet eine umfangreiche Analyse darüber, welche Ergebnisse mit welchen Standardverfahren erreichbar sind, und gibt, davon abgeleitet, Empfehlungen für die Implementierung und die weitere Forschung.

4.5.2 Weitergehende Forschungsfragen

In der Adaption und Weiterentwicklung der verwendeten Verfahren liegt das Potential, die vorgestellten Ergebnisse zu verbessern. Ein möglicher Fokus ergibt sich aus einem Aspekt der vorliegenden Analyse: In dem LR-Modell, welches in den durchgeführten Experimenten insgesamt die besten Ergebnisse erzielt hat, wurde für jede halbe Stunde des Tages ein eigenes Modell implementiert, während in den anderen Modellen die Uhrzeit als weitere Input-Variable modelliert wurde. Das legt nahe, dass die Tageszeit ein wesentlicher Faktor ist und dass der Einfluss der Tageszeit in den anderen Modellen erhöht werden könnte. Dazu können ebenfalls 48 Modelle, für jede halbe Stunde des Tages eines, implementiert werden. Bei den k-nächsten Nachbarn kann der Einfluss der Tageszeit als Input-Variable auch durch eine andere Skalierung erhöht werden.

Für alle Methoden gilt, dass bei einer gezielten Anpassung der Parameter an eine spezifische Datenreihe, eventuell bessere Ergebnisse erreichbar sind. Die Implementierung eines vorgelagerten Auswahlprozesses müsste dann entsprechend automatisiert erfolgen.

In der Analyse der Experimente wurde ein Zusammenhang zwischen dem Variationskoeffizienten und der Prognosegüte aufgezeigt. Diese These sollte zum einen auf weiteren Datensätzen evaluiert werden. Zum anderen legt sie nahe, dass der Variationskoeffizient ein geeignetes Kriterium für die Auswahl der Methode oder der

Modellspezifikation sein könnte.

Im Forschungsbereich des „Non-intrusive appliance load monitoring“ werden Verfahren entwickelt, welche aus den Smart-Meter-Daten eines Haushaltes einzelne Verbraucher identifizieren können (vgl. [136–138]). Auf welche Weise dies in der Erstellung von Prognoseverfahren genutzt werden kann, ist ein weiteres unerschlossenes Forschungsfeld.

Neben den vorgestellten Möglichkeiten, die Stromlastprognosen weiterzuentwickeln, sollten die Verfahren in den nachgelagerten Anwendungsszenarien evaluiert werden.

4.6 Zusammenfassung

Kurzfristige Stromlastprognosen sind eine wichtige Komponente in der Implementierung von Energiemanagementsystemen in einzelnen Haushalten, Wohnblöcken und Microgrids. In der vorliegenden Arbeit wurde zunächst in einem strukturierten Literaturreview analysiert, welche Verfahren bereits evaluiert wurden und welche Schlüsse sich aus den jeweiligen Auswertungen ziehen lassen. Dabei wird deutlich, dass sich aus den vorhandenen Studien kaum allgemein gültige Empfehlungen ableiten lassen, da die jeweiligen Analysen oft nur auf projekt-internen Datensätzen durchgeführt wurden. Die Datenreihen einzelner Haushalte unterscheiden sich wesentlich, was sich in sehr unterschiedlichen Ergebnissen der verschiedenen Artikeln äußert. Ein Vergleich der Methoden wird zudem dadurch erschwert, dass verschiedene Kennzahlen zur Bewertung der Prognosegüte verwendet werden.

Diese Forschungslücke wurde in der vorliegenden Arbeit geschlossen. Es wurden sieben State-of-the-Art Verfahren implementiert und auf insgesamt 165 Datenreihen mit verschiedenen Aggregationsleveln hinsichtlich ihrer Prognosegüte untersucht. Diese wurde in drei verschiedenen skalierbaren Kennzahlen gemessen. Mittels dieses explorativen Ansatzes wurde aufgezeigt, welche Prognosegenauigkeit mit welcher Methode erreicht werden kann und wie sich die Kennzahlen bei zunehmendem Aggregationsgrad und steigendem Prognosehorizont entwickeln. In der Analyse führte das implementierte LR-Modell insgesamt zu den besten Ergebnissen, wobei die Ergebnisse in einzelnen Settings abwichen. Die k-nächste-Nachbarn-Regression erreichte annähernd ähnlich gute Resultate wie LR, während die anderen implementierten Verfahren höchstens in einzelnen Settings bessere Ergebnisse aufwiesen, in den meisten jedoch abfielen.

Die Prognosen für einzelne Haushalte waren mit einem durchschnittlichen MAPE von 33 – 52%, einem NMAE von 34 – 45% und einem NRMSE 48 – 55% für die Prognosen eine halbe Stunde im Voraus ziemlich inakkurat. Die Prognosefehler nahmen bei steigendem Aggregationsgrad ab. Für die aggregierten Datensätze von 10 Haushalten beliefen sich die Prognosefehler nur noch auf einen durchschnittlichen MAPE von 17 – 21%, einen NMAE von 18 – 20% und einen NRMSE von 25%. Für den Datensatz von 100 aggregierten Haushalten betrugen die Fehler weniger als 7 – 9%. Diese Ergebnisse legen nahe, dass, sofern möglich, mehrere Haushalte in der

Prognose und dem nachgelagerten Optimierungsprozess betrachtet werden sollten. In den Experimenten wurde – soweit bekannt erstmals – ein starker Zusammenhang zwischen dem Variationskoeffizienten der Stromlasten und der Prognosegenauigkeit aufgezeigt und in einer logarithmischen Regressionskurve modelliert. Damit kann die erwartbare Prognosegüte für eine Datenreihe vorab abgeschätzt werden.

Die Prognosefehler stiegen mit zunehmendem Prognosehorizont an. So waren die Ergebnisse für 2 Stunden im Voraus deutlich schlechter als für eine halbe Stunde im Voraus. Der Unterschied zwischen der Prognosegüte für 2 und 4 Stunden im Voraus war dagegen sehr gering. Für die weiteren evaluierten Prognosehorizonte von 8 und 48 Stunden im Voraus blieb der Fehler dann stabil auf dem Niveau der Prognosen 4 Stunden im Voraus. In den Experimenten wurden verschiedene Input-Variablen für jedes Modell evaluiert und in der anschließenden Analyse methodenspezifische Implikationen dargestellt. In der anschließenden Diskussion wurden die Limitierungen der Arbeit benannt und weitergehende Forschungsfragen aufgestellt.

Zusammengefasst gibt die vorliegende Arbeit einen umfassenden Überblick über den Stand der Forschung an kurzfristigen Stromlastprognosen und unterbreitet durch die umfängliche Analyse von sieben State-of-Art-Methoden Erkenntnisse und Empfehlungen für die Implementierung und die weitere Forschung von kurzfristigen Stromlastprognosen:

- Es sind reproduzierbare Benchmarks in diversen Settings auf öffentlich verfügbaren Datensätzen erstellt worden.
- Dabei erreichten auf den evaluierten Datensätzen eine lineare Regression und k-nächste-Nachbarn die besten Resultate.
- Es wurde ein starker Zusammenhang zwischen dem Variationskoeffizienten und der Prognosegüte nachgewiesen und durch eine logarithmische Regressionskurve abgeschätzt.
- Die Prognosegüte nahm bei steigendem Prognosehorizont für die ersten vier Stunden ab, im Anschluss blieb sie stabil.
- Für jedes implementierte Verfahren wurden aus der Analyse der Input-Variablen methodenspezifische Empfehlungen abgeleitet.

Zusammenfassung und Ausblick

Contents

5.1	Zusammenfassung der Arbeit	136
5.2	Abschließende Bewertung der Optimierungsansätze	139
5.3	Forschungsbedarf und Ausblick	140

5.1 Zusammenfassung der Arbeit

Durch die Vernetzung von lokalen Erzeugern und Verbrauchern zu Microgrids eröffnet sich die Möglichkeit, die Energieversorgung vor Ort zu koordinieren und die CO₂-Emissionen der Energieversorgung zu reduzieren. Zur Evaluierung der damit einhergehenden Potentiale wurde in der vorliegenden Arbeit ein Optimierungsverfahren zur Steuerung der lokalen Erzeuger entwickelt, Optimierungsverfahren auf Seiten der Verbraucher adaptiert und deren Wirksamkeit jeweils mittels Simulationen quantifiziert. Ergänzt wurden diese durch eine umfassende Analyse von kurzfristigen Stromlastprognosen auf Verbraucherebene. Zu jedem Forschungsansatz wurde in dem jeweiligen Kapitel eine Diskussion über die Limitierungen und die weitergehende Forschungsfragen geführt. Dieses Kapitel stellt die verschiedenen Ansätze und die Haupteckdaten zusammenfassend dar. In einer abschließenden Bewertung werden die Effekte der Optimierungsverfahren gegenübergestellt und die Bedeutung im Gesamtkontext der Energienetze diskutiert. Der letzte Abschnitt gibt einen Ausblick und führt den weitergehenden Forschungsbedarf aus.

Optimierung auf Erzeugerseite Zur Optimierung der lokalen Energieerzeugung wurde die Kombination eines Mikro-BHKW mit PV-Anlagen als lokale Stromerzeuger in einem Microgrid betrachtet. Die grundlegende Idee beruht darauf, dass sich diese Einheiten über den Lauf des Jahres gut ergänzen. Das Mikro-BHKW ist insbesondere im Winter effizient, wenn ein hoher Bedarf an Wärme besteht, während die PV-Anlagen im Sommer viel Strom bereitstellen. Zur Umsetzung wurde eine koordinative Betriebsführung für ein Mikro-BHKW entwickelt, bei welcher die aktuellen und prognostizierten Zustände der anderen Einheiten im Microgrid berücksichtigt werden. Auf Basis von realen Verbrauchsdaten wurde das Verfahren für Microgrids mit unterschiedlichen Ausstattungen simuliert und ausgewertet. In einer Robustheitsanalyse wurde zudem analysiert, wie stabil die Ergebnisse gegenüber zufälligen Fehlern in den Prognosen des Strombedarfs und der Solarstromerzeugung sind.

Die detaillierten Ergebnisse der Simulationen sind in Kapitel 2.5 dargestellt. Eine der Hauptaussagen liegt darin, dass durch diesen Ansatz ein hoher Selbstversorgungsgrad in der Energieversorgung erreicht wird. In der Simulation konnten durch die lokale Stromerzeugung 85% des Strombedarfs gedeckt werden, wobei der Anteil der lokalen Stromversorgung in jedem Monat mindestens 74% betrug. Die CO₂-Emissionen wurden somit um 65%, bezogen auf die Stromversorgung, und um 33%, bezogen auf die gesamte Energieversorgung, reduziert. Diese Ergebnisse erwiesen sich als robust gegenüber den modellierten Prognosefehlern. Die Vorteile eines solches Konzepts zeigen sich auch in der Auswertung der Betriebskosten. In der Simulation wurde eine Reduktion der laufenden Energiekosten bis zu 45% erreicht. Zudem wurde der Netzbezug durch diesen Ansatz deutlich reduziert und die täglichen Spitzenlasten durchschnittlich um 68% gesenkt. Bei zeitvariablen Strompreisen wurde der verbleibende Strombezug in Zeiten verlagert, in welchen ein günstiger Strompreis vorlag.

Damit stellen der Zusammenschluss von mehreren Haushalten zu einem Microgrid und die Kombination mit einer koordinierten Betriebsführung von einem Mikro-BHKW und PV-Anlagen ein mögliches Konzept dar, die CO₂-Emissionen in der Energieversorgung zu senken und zudem die Übertragungsnetze zu entlasten.

Optimierung auf Verbraucherseite Zu der Anpassung des Strombedarfs an die Erzeugung wurden Haushaltgeräte mit verschiebbaren Lasten betrachtet. Dabei richtete sich der Fokus auf Wasch- und Geschirrspülmaschinen sowie Trockner. Denn diese stellen die wesentlichen Großverbraucher auf Haushaltsebene dar, bei welchen man annehmen kann, dass sich die Nutzer auf automatisierte Lastverschiebungen einlassen. Dabei wurden zwei Zielsetzungen zur Anpassung des Strombedarfs betrachtet:

- die Glättung des Strombezugs vor Ort und
- die Anpassung an vorgegebene Strompreise, welche die Auslastung der übergeordneten Stromnetze widerspiegeln.

Auch methodisch wurden zwei Ansätze untersucht:

- Die individuelle Optimierung jedes Haushaltes für sich und
- koordinative Verhandlungen zwischen den Haushalten nach dem Konzept von Mohsenian-Rad [2].

Auf Basis realer Verbrauchsdaten wurden die Verfahren für Microgrids simuliert und ausgewertet. Die detaillierten Ergebnisse sind in Kapitel 3.5 dargestellt.

Bei den verwendeten Verbrauchsdaten waren ca. 10% der Stromlasten verschiebbar. Der durchschnittliche Anteil der verschiebbaren Lasten an den Spitzenlasten betrug ebenfalls 10%. In der Simulation wurde durch den koordinativen Ansatz bereits bei Lastverschiebungen von maximal einer Stunde eine durchschnittliche Spitzenlastreduktion von 8% erreicht. Dies zeigt, dass bereits geringe zeitliche Verschiebungen

deutlich zur Reduktion der Spitzenlasten beitragen können. Die Ergebnisse zeigen weiterhin, dass für diese Zielsetzung der koordinative Ansatz dem individuellen DSM weitaus überlegen ist. Letzteres erreichte für dasselbe Setting nur eine Spitzenlastreduktion von 2%. Für den koordinativen Ansatz ist diese Analyse zudem ein Beleg dafür, dass es auch bei realen Lastprofilen zu guten Ergebnissen führt, selbst wenn die theoretische Konvergenz gegen das globale Maximum nicht sichergestellt ist.

Im Hinblick auf die CO₂-Emissionen wurde in der Simulation eine maximale Reduktion von 7% erreicht. Auch wenn die hierfür verwendete Annahme, dass die zeitvariablen Strompreise mit dem Anteil der erneuerbaren Energien im Stromnetz korreliert sind, eine Vereinfachung darstellt, gibt das Resultat Aufschluss über das Potential, welches in der Anwendung von DSM in Bezug auf die CO₂-Emissionen liegt. Die Umsetzung geeigneter zeitvariabler Stromtarife wäre zugleich ein monetärer Anreiz für den Endverbraucher sich auf DSM einzulassen.

Kurzfristige Stromlastprognose Für die Umsetzung beider Optimierungsverfahren bedarf es kurzfristiger Stromlastprognosen für Haushalte. Zur Identifikation von geeigneten Verfahren und zur Abschätzung der erwartbaren Prognosegüte wurden in einem umfassenden Literaturreview die Prognosegenauigkeiten von bereits evaluierten Verfahren der verwandten Literatur gegenübergestellt. Die Ergebnisse waren teilweise widersprüchlich und konnten aufgrund der Verwendung von projekt-internen Datensätzen nicht reproduziert werden. In der vorliegenden Arbeit wurden daher sieben State-of-the-Art Verfahren implementiert und auf 165 öffentlich verfügbaren Datensätzen für verschiedene Prognosehorizonte evaluiert. Die Prognosefehler wurden im Hinblick auf die Skalierungseffekte, den Prognosehorizont und die verwendeten Input-Variablen analysiert.

Die detaillierte Analyse der Experimente ist in Kapitel 4.4 dargestellt. Zu den zentralen Erkenntnissen gehört, dass die lineare Regression in vielen Settings zu den kleinsten Prognosefehlern führt und damit eine einfache und erfolgreiche Methode zur Erstellung von kurzfristigen Stromlastprognosen zu sein scheint. Unter der Verwendung bestimmter Kennzahlen zur Bewertung der Prognosegüte erzielt die nächste-Nachbarn-Regression kompetitive Ergebnisse. Andere Methoden weisen nur für einzelne Settings vergleichbare oder bessere Ergebnisse auf.

Die durchschnittlichen Prognosefehler nehmen bei einem steigenden Aggregationsgrad ab. Es wurde in einer Regressionsanalyse gezeigt, dass ein starker Zusammenhang zwischen dem Variationskoeffizienten einer Verbrauchsdatenreihe und der Prognosegüte besteht. Dieser lässt sich durch logarithmische Regressionskurven gut abschätzen. So lässt sich der NMAE für die Prognosen mittels der linearen Regression eine halbe Stunde im Voraus beispielsweise mit der Funktion $g(x) = 0,49 \ln(x) + 0,45$ aus dem Variationskoeffizienten mit einem Bestimmtheitsmaß von 0,84 bestimmen.

Ein steigender Prognosehorizont führt wiederum zu einem wachsenden Prognosefehler. Die Prognosefehler sind für einen Prognosehorizont von vier Stunden im Voraus deutlich höher als eine halbe Stunde im Voraus. Für längere Prognosehori-

zonte von vier Stunden bis zu einem Tag im Voraus sind die Fehler ungefähr gleich hoch. Aus der Analyse der Input-Variablen wurden methoden- und kennzahl-spezifische Empfehlung für die Auswahl abgeleitet.

Insgesamt sind die Prognosefehler für einzelne Haushalte relativ hoch. Die durchschnittlichen Prognosefehler liegen für Prognosen eine halbe Stunde im Voraus zwischen 33% und 55%. Sie nehmen jedoch bei steigendem Aggregationsgrad stark ab. Bei einem Zusammenschluss von 10 Haushalten halbierten sich die durchschnittlichen Fehler in den Experimenten. Für eine Verwendung von kurzfristigen Stromlastprognosen empfiehlt es sich daher, gemeinsame Prognosen für mehrere Haushalte zu erstellen, sofern dies die nachgelagerte Anwendung zulässt. Eine Abschätzung der Prognosegüte kann im Vorfeld durch den Variationskoeffizienten erfolgen.

5.2 Abschließende Bewertung der Optimierungsansätze

Die Entwicklung der Optimierungsverfahren und die Auswertung auf den simulierten Microgrids offenbart das Potential, welches in der lokalen Optimierung der Energieversorgung liegt. Im direkten Vergleich der angewandten Optimierungsverfahren wird deutlich, dass das Potential zur Reduktion der CO₂-Emissionen und der Reduktion der Spitzenlasten auf der Erzeugerseite wesentlich höher ist als auf der Verbraucherseite. Durch die koordinierte Energieerzeugung wurden in der Simulation 65% der CO₂-Emissionen bezogen auf die Stromversorgung vermieden. Bei der simulierten Verschiebung der Lasten auf Verbraucherseite betrug der Effekt maximal 7%. Bei der möglichen Spitzenlastreduktion stehen den 68% durch die Optimierung auf Erzeugerseite, maximal 10% auf Verbraucherseite gegenüber. Zudem können durch einen Umstieg von Erdgas auf Biogas in der lokalen Energieerzeugung weitere Einsparungen erreicht werden. Nach den Ergebnissen der Simulation würde in diesem Fall nur noch **ein Fünftel der CO₂-Emissionen** im Vergleich zu einer konventionellen Energieversorgung verursacht werden. Diese Ergebnisse sind zwar unter den beschriebenen Limitierungen (vgl. Abschnitt 2.6.1) zu betrachten, weisen jedoch einen möglichen Weg zu der Erreichung der eingangs beschriebenen europäischen Klimaziele.

Zu den positiven Effekten der Optimierung auf Erzeugerseite tragen insbesondere drei konzeptionelle Maßnahmen bei:

1. die gemeinsame Betrachtung der Strom- und Wärmeversorgung,
2. die Kombination einer KWK-Anlage mit PV-Anlagen,
3. die koordinierte, prädiktive Steuerung der Komponenten.

Die Vorteile werden durch den Zusammenschluss von mehreren Wohnungen und den Erzeugungseinheiten zu einem Microgrid ermöglicht. Die Investitionskosten für eine KWK-Anlage rentieren sich ökonomisch erst ab einem gewissen Auslastungsgrad. Durch die gemeinsame Nutzung und die koordinative Steuerung werden der Auslastungsgrad und insbesondere der profitable Eigenverbrauch des erzeugten Stroms

erhöht. Dies gilt gleichermaßen für die Nutzung der Solaranlagen. Darüber hinaus werden für die vorausschauende Optimierung Prognosen für den kurzfristigen Stromverbrauch benötigt. In der Analyse der geeigneten Verfahren in Kapitel 4.4 wurde deutlich, dass die Prognosegüte von der Variabilität des Stromverbrauchs abhängt und dass diese für einzelne Haushalte i.d.R. relativ hoch ist. Durch den Zusammenschluss zu einem Microgrid verringern sich die Prognosefehler.

Im Vergleich zu dem Potential, welches sich auf der Erzeugerseite offenbart, wirken die durch die Lastverschiebungen auf Verbraucherseite erzielten Effekte eher gering. Allerdings sollten diese nicht als Konkurrenz, sondern als zusätzliche Option der Optimierung betrachtet werden. Auch die verschiedenen Ansätze, welche für die Umsetzung von DSM evaluiert wurden, müssen nicht in direkter Konkurrenz stehen. So lässt sich das individuelle DSM bereits ohne Microgridstruktur umsetzen und kann bereits heute in entsprechend ausgestatteten Haushalten realisiert werden. Notwendig sind dafür jedoch geeignete Anreizmaßnahmen, welche die Verbraucher zur Nutzung von DSM motivieren. Zu diesem Zweck könnten beispielsweise zeitvariable Stromtarife oder Boni für die Nutzung von DSM eingeführt werden. Für einen flächendeckenden Einsatz empfiehlt sich der koordinative Ansatz, da somit mögliche negative Rückkopplungseffekte vermieden werden und zudem die Effekte bereits bei geringer zeitlicher Flexibilität deutlich höher sind. Dazu bedarf es neben finanziellen Anreizen eine entsprechende Kommunikationsinfrastruktur und sichere Verhandlungsprotokolle.

Für die Anwendung der kurzfristigen Stromlastprognosen empfiehlt es sich stets, die Stromlasten mehrerer Haushalte gemeinsam zu betrachten. In den Experimenten konnten für einzelne Haushalte aufgrund der hohen Variabilität im Stromverbrauch keine verlässlichen Prognosen erzielt werden. Der Zusammenschluss zu einem Microgrid ist ein guter Ansatz, dieses Problem zu umgehen, da sich die Prognosegüte bei der Aggregation von bereits wenigen Haushalten deutlich verbessert. Da die Prognosefehler bei steigendem Prognosehorizont ansteigen, erscheint es zweckmäßig in der nachfolgenden Optimierung regelmäßige Updates vorzusehen, in welche aktualisierte Prognosen eingehen. Die durchgeführten Experimente bieten Anhaltspunkte für die erwartbaren Prognosefehler und stellen Benchmarks für die weitere Entwicklung von kurzfristigen Stromlastprognosen dar.

5.3 Forschungsbedarf und Ausblick

Zur Evaluation der entwickelten Optimierungsverfahren wurden teilweise vereinfachende Modellannahmen getroffen, welche in weiteren Forschungsarbeiten untersucht werden sollten. So wurden in der Optimierung der Energieerzeugung die Wärmeverluste durch eine Speicherung im Warmwasserspeicher vernachlässigt. Um abzuschätzen, welche Einfluss diese Verluste auf die Energiebilanzen und die CO₂-Emissionen haben, bedarf es einer detaillierteren Modellierung des Wärmefflusses und empirischer Datensätze über den Wärmebedarf von Haushalten, mit welchen das Modell validiert werden kann. Bei der Analyse der DSM-Verfahren wurde an-

genommen, dass der Strombedarf und die zeitvariablen Strompreise 24 h im Voraus bekannt sind. Eine Robustheitsanalyse würde Aufschluss darüber geben, ob sich die angewandten DSM-Verfahren auch bei fehlerbehafteten Prognosen bewähren. Für beide Optimierungsansätze besteht die Option, die Algorithmen dahingehend zu erweitern, dass sie sich in regelmäßigen Abständen aktualisieren und neu berechnete Prognosen berücksichtigen. Bei den verwendeten Prognoseverfahren handelt es sich jeweils um Standardverfahren, daher besteht das Potential durch die Adaptierung und Weiterentwicklung dieser die vorgestellten Ergebnisse zu verbessern.

Die angewandten Optimierungsverfahren und die Simulationen machen deutlich, welches Potential in der lokalen Optimierung in Microgrids liegt. Die konkrete Umsetzung birgt jedoch noch einige Herausforderungen. Es bedarf kompatibler Kommunikationsstandards – sowohl innerhalb des Microgrids als auch zu den übergeordneten Leitsystemen. Derzeit existieren verschiedene Kommunikationssysteme für Smart-Home und Smart-Energy-Anwendungen, was zu Problemen bezüglich der Kompatibilität von Geräten verschiedener Hersteller führt. Im Bereich der Gebäudeautomation setzt sich die EEBus Initiative – entstanden aus dem Förderprogramm E-Energy – für eine Vereinheitlichung der Normen ein [139]. Für die Kommunikation des übergeordneten Netzmanagement wurden in der DKE-Standardisierungsroadmap fünf europäische IEC Normen als Kernstandards hervorgehoben (vgl. [140]). Die Entwicklung hin zu allgemein akzeptierten Normen und die Weiterentwicklung dieser sind wichtige Schritte in der Neuausrichtung der Energienetze. Dabei müssen sowohl der Schutz der personenbezogenen Daten als auch der Schutz vor Angriffen auf die Kommunikationsprozesse gewährleistet sein.

Weiterhin bedarf es geeigneter Geschäftsmodelle für den Betrieb von Microgrids. Dabei sind verschiedene Optionen denkbar. Nach der aktuellen Gesetzgebung könnten die erzeugenden Komponenten im Microgrid als Kundenanlage betrieben werden, d.h. als eine Stromversorgungseinrichtung, die nicht als Netz angesehen wird und daher nicht der Regulierung nach dem Energiewirtschaftsgesetz unterliegt [141]. Der Betrieb könnte entweder von einer Eigentümergemeinschaft, dem Vermieter der angebundenen Wohnungen oder einem Dienstleistungsunternehmen, einem sogenannten Contractor, geführt werden. Dabei gilt zu beachten, dass auch innerhalb einer Kundenanlage jeder angeschlossene Letztverbraucher seinen Energielieferanten frei wählen darf. Da der Aufbau eines Microgrids mit erheblichen Investitionskosten verbunden ist, bedarf es verlässlicher rechtlicher und politischer Maßnahmen, welche die Investitionen langfristig planbar zu machen. Für die Umsetzung von DSM bedarf es zudem von Seiten der Energieversorger tarifliche Anreize, um den Endverbraucher zur Nutzung von DSM zu motivieren.

Der deutsche Politiker Hermann Scheer prägte vor mehr als zehn Jahren den folgenden Satz: „Die Mehrkosten für erneuerbare Energien von heute sind gesicherte Energie, vermiedene Umweltschäden und niedrige Energiekosten von morgen.“ (vgl. [142]). Dieses Zitat hat nichts von seiner Bedeutung verloren, sondern ist vielmehr aktueller denn je.

Appendix

A.1 Ergebnisse der ADF-Tests

Die Zeitreihen wurden einzeln mittels des Augemented-Dickey-Fuller Tests auf Differenzen-Stationarität getestet. Dabei liegt die ermittelte Teststatistik τ_{ADF} jeweils deutlich unter den kritischen Werten der Irrtumswahrscheinlichkeiten von 1%, 5%, 10% gemäß [143], so dass die These der Differenzen-Stationarität verworfen und somit stochastische Trends ausgeschlossen werden können. Dieses Befund wird zudem gestützt durch die Ergebnisse der p -Werte nach MacKinnon [144], welche für jede Zeitreihe deutlich unter 0,05 liegen. Die Berechnungen wurden jeweils auf der ersten Trainingsmenge einer Datenreihe unter Nutzung von Statsmodels, der Bibliothek für statistische und ökonometrische Analyse in Python, durchgeführt [145]. Die Ergebnisse sind in der folgenden Tabelle A.1 dargestellt.

Tabelle A.1: ADF-Teststatistiken und p -Werte für die Datenreihen aus CER

kritische Werte der Teststatistiken		
1%-Level	5%-Level	10%-Level
-3,44	-2,87	-2,57
Datenreihe	τ_{ADF}	p-Wert
REDD Haushalt 0	-5,50	2,12E-06
REFIT Haushalt 2	-12,13	1,76E-22
REFIT Haushalt 3	-13,59	2,07E-25
REFIT Haushalt 4	-16,54	1,99E-29
REFIT Haushalt 6	-13,55	2,39E-25
REFIT Haushalt 7	-13,56	2,30E-25
REFIT Haushalt 10	-15,49	2,48E-28
REFIT Haushalt 11	-8,98	7,27E-15
REFIT Haushalt 15	-33,16	0
REFIT Haushalt 17	-7,81	6,92E-12
REFIT Haushalt 18	-11,49	4,76E-21
REFIT Haushalt 19	-13,64	1,68E-25
REFIT Haushalt 20	-15,35	3,73E-28
CER Haushalt 1000	-14,58	4,51E-27
CER Haushalt 1003	-12,67	1,22E-23
CER Haushalt 1004	-16,83	1,16E-29
CER Haushalt 1005	-10,01	1,76E-17

CER Haushalt 1007	-16,29	3,32E-29
CER Haushalt 1008	-12,73	9,37E-24
CER Haushalt 1009	-11,45	5,95E-21
CER Haushalt 1013	-13,16	1,31E-24
CER Haushalt 1014	-12,43	4,04E-23
CER Haushalt 1015	-13,50	2,93E-25
CER Haushalt 1018	-8,81	1,96E-14
CER Haushalt 1019	-13,73	1,15E-25
CER Haushalt 1020	-18,36	2,23E-30
CER Haushalt 1024	-9,33	9,14E-16
CER Haushalt 1025	-15,61	1,79E-28
CER Haushalt 1027	-17,45	4,67E-30
CER Haushalt 1029	-16,42	2,53E-29
CER Haushalt 1030	-16,72	1,41E-29
CER Haushalt 1031	-14,32	1,14E-26
CER Haushalt 1033	-19,08	0
CER Haushalt 1034	-11,80	9,55E-22
CER Haushalt 1037	-13,51	2,89E-25
CER Haushalt 1039	-14,39	8,92E-27
CER Haushalt 1041	-38,70	0
CER Haushalt 1044	-11,64	2,12E-21
CER Haushalt 1046	-18,55	2,10E-30
CER Haushalt 1047	-22,01	0
CER Haushalt 1051	-14,18	1,97E-26
CER Haushalt 1054	-19,07	0
CER Haushalt 1057	-13,97	4,44E-26
CER Haushalt 1059	-11,90	5,63E-22
CER Haushalt 1060	-11,79	9,85E-22
CER Haushalt 1061	-16,16	4,45E-29
CER Haushalt 1063	-13,34	6,07E-25
CER Haushalt 1065	-17,62	3,83E-30
CER Haushalt 1066	-14,37	9,63E-27
CER Haushalt 1067	-15,11	7,71E-28
CER Haushalt 1071	-13,28	7,72E-25
CER Haushalt 1073	-15,21	5,68E-28
CER Haushalt 1075	-15,95	7,44E-29
CER Haushalt 1076	-9,86	4,30E-17
CER Haushalt 1077	-16,95	9,52E-30
CER Haushalt 1079	-13,64	1,68E-25
CER Haushalt 1081	-13,38	4,92E-25
CER Haushalt 1082	-12,85	5,41E-24
CER Haushalt 1083	-17,80	3,22E-30
CER Haushalt 1084	-14,23	1,58E-26

CER Haushalt 1085	-14,12	2,47E-26
CER Haushalt 1087	-17,70	3,54E-30
CER Haushalt 1088	-11,00	6,57E-20
CER Haushalt 1091	-11,39	8,10E-21
CER Haushalt 1093	-18,55	2,09E-30
CER Haushalt 1096	-13,41	4,33E-25
CER Haushalt 1097	-9,58	2,15E-16
CER Haushalt 1098	-18,52	2,11E-30
CER Haushalt 1099	-18,80	2,02E-30
CER Haushalt 1100	-12,85	5,27E-24
CER Haushalt 1105	-10,65	4,64E-19
CER Haushalt 1107	-16,75	1,33E-29
CER Haushalt 1108	-17,42	4,82E-30
CER Haushalt 1109	-12,29	7,88E-23
CER Haushalt 1110	-15,62	1,75E-28
CER Haushalt 1111	-16,33	3,07E-29
CER Haushalt 1115	-12,72	9,80E-24
CER Haushalt 1117	-18,30	2,29E-30
CER Haushalt 1118	-20,10	0
CER Haushalt 1119	-14,88	1,61E-27
CER Haushalt 1121	-12,32	6,91E-23
CER Haushalt 1122	-15,91	8,11E-29
CER Haushalt 1123	-12,08	2,23E-22
CER Haushalt 1124	-16,33	3,09E-29
CER Haushalt 1125	-9,27	1,36E-15
CER Haushalt 1128	-12,41	4,41E-23
CER Haushalt 1129	-12,66	1,30E-23
CER Haushalt 1130	-16,00	6,55E-29
CER Haushalt 1132	-21,18	0
CER Haushalt 1133	-17,60	3,94E-30
CER Haushalt 1136	-14,75	2,53E-27
CER Haushalt 1138	-15,56	2,07E-28
CER Haushalt 1139	-17,00	8,78E-30
CER Haushalt 1140	-19,33	0
CER Haushalt 1141	-16,84	1,15E-29
CER Haushalt 1143	-12,78	7,38E-24
CER Haushalt 1144	-16,76	1,32E-29
CER Haushalt 1148	-12,64	1,46E-23
CER Haushalt 1154	-17,03	8,31E-30
CER Haushalt 1155	-10,32	2,96E-18
CER Haushalt 1156	-14,55	4,98E-27
CER Haushalt 1157	-12,40	4,61E-23
CER Haushalt 1162	-16,30	3,25E-29

CER Haushalt 1164	-10,70	3,58E-19
CER Haushalt 1165	-13,02	2,43E-24
CER Haushalt 1168	-14,75	2,47E-27
CER Haushalt 1170	-11,72	1,41E-21
CER Haushalt 1174	-16,70	1,47E-29
CER Haushalt 1176	-11,85	7,09E-22
CER Haushalt 1178	-15,39	3,36E-28
CER Haushalt 1180	-12,93	3,71E-24
CER Haushalt 1182	-13,92	5,30E-26
CER Haushalt 1183	-12,40	4,63E-23

Literaturverzeichnis

- [1] T. Benz, J. Dickert, M. Erbert, N. Erdmann, C. Johae, B. Katzenbach, B. Glaunsinger, H. Müller, P. Schegner, J. Schwarz, et al., VDE-Studie: Der Zellulare Ansatz – Grundlage einer erfolgreichen, regionenübergreifenden Energiewende, VDE, ETG, Frankfurt a. M. (Zitiert auf den Seiten iv, 2 and 50.)
- [2] A.-H. Mohsenian-Rad, V. W. Wong, J. Jatskevich, R. Schober, A. Leon-Garcia, Autonomous demand-side management based on game-theoretic energy consumption scheduling for the future smart grid, IEEE transactions on Smart Grid 1 (3) (2010) 320–331. (Zitiert auf den Seiten v, 51, 54, 55, 62, 63, 64 and 137.)
- [3] J. vom Brocke, A. Simons, B. Niehaves, K. Riemer, R. Plattfaut, A. Cleven, Reconstructing the giant: On the importance of rigour in documenting the literature search process, in: 17th European Conference on Information Systems, ECIS 2009, Verona, Italy, 2009, 2009, pp. 2206–2217. (Zitiert auf den Seiten v, 5, 82 and 83.)
- [4] E-Energy Abschlussbericht: Ergebnisse und Erkenntnisse aus der Evaluation der sechs Leuchtturmprojekte, http://www.e-energie.info/documents/E-Energy_Ergebnisbericht_Handlungsempfehlungen_BAUM_140212.pdf, letzter Zugriff am 13.01.2017 (2013). (Zitiert auf Seite 1.)
- [5] The European Parliament and the Council of the European Union, Directive 2009/28/ec, Official Journal of the European Union L 140/16. (Zitiert auf den Seiten 1 and 8.)
- [6] Bundesministerium für Umwelt, Naturschutz, Bau und Reaktorsicherheit, Klimaschutzplan 2050 – Klimaschutzpolitische Grundsätze und Ziele der Bundesregierung, http://www.bmub.bund.de/fileadmin/Daten_BMU/Download_PDF/Klimaschutz/klimaschutzplan_2050_bf.pdf, letzter Zugriff am 13.01.2017 (2016). (Zitiert auf Seite 1.)
- [7] J. G. Charney, A. Arakawa, D. J. Baker, B. Bolin, R. E. Dickinson, R. M. Goody, C. E. Leith, H. M. Stommel, C. I. Wunsch, Carbon dioxide and climate: a scientific assessment (1979). (Zitiert auf Seite 1.)
- [8] S. Solomon, Climate change 2007-the physical science basis: Working group I contribution to the fourth assessment report of the IPCC, Vol. 4, Cambridge University Press, 2007. (Zitiert auf Seite 1.)
- [9] J. Hansen, M. Sato, P. Kharecha, D. Beerling, R. Berner, V. Masson-Delmotte, M. Pagani, M. Raymo, D. L. Royer, J. C. Zachos, Target atmospheric co₂:

- Where should humanity aim?, arXiv preprint arXiv:0804.1126. (Zitiert auf Seite 1.)
- [10] The European Parliament and the Council of the European Union, Decision no 406/2009/ec, Official Journal of the European Union L 140/136. (Zitiert auf den Seiten 1 and 8.)
- [11] C. Europea, A policy framework for climate and energy in the period from 2020 to 2030, COM (2014) 15. (Zitiert auf den Seiten 1 and 8.)
- [12] Bundesministerium für Wirtschaft und Energie, Fünfter Monitoring-Bericht zur Energiewende: Energie der Zukunft, <https://www.bmwi.de/BMWi/Redaktion/PDF/Publikationen/fuenfter-monitoring-bericht-energie-der-zukunft,property=pdf,bereich=bmwi2012,sprache=de,rwb=true.pdf>, letzter Zugriff am 13.01.2017 (2015). (Zitiert auf Seite 2.)
- [13] Bundesministerium für Wirtschaft und Energie (BMWi), Erneuerbare Energien in Zahlen, Nationale und internationale Entwicklung im Jahr 2015, <https://www.bmwi.de/Redaktion/DE/Publikationen/Energie/erneuerbare-energien-in-zahlen-2015-09.html>, letzter Zugriff am 13.01.2017 (2016). (Zitiert auf Seite 2.)
- [14] Bundesnetzagentur für Elektrizität, Gas, Telekommunikation, Post und Eisenbahnen, Bundeskartellamt, Monitoringbericht 2016 (2016). (Zitiert auf Seite 2.)
- [15] M. Fürsch, R. Malischek, D. Lindenberger, et al., Der Merit-Order-Effekt der erneuerbaren Energien-Analyse der kurzen und langen Frist, Nr 12 (2012) 14. (Zitiert auf den Seiten 2, 12 and 50.)
- [16] A. Kießling, Modellstadt Mannheim (moma): Abschlussbericht; Beiträge von moma zur Transformation des Energiesystems für Nachhaltigkeit, Beteiligung, Regionalität und Verbundenheit; E-Energy-IKT-basiertes Energiesystem der Zukunft, MVV Energie, 2013, letzter Zugriff am 13.01.2017. (Zitiert auf den Seiten 2 and 56.)
- [17] C. Marnay, S. Chatzivasileiadis, C. Abbey, R. Iravani, G. Joos, P. Lombardi, P. Mancarella, J. von Appen, Microgrid evolution roadmap, in: Smart Electric Distribution Systems and Technologies (EDST), 2015 International Symposium on, IEEE, 2015, pp. 139–144. (Zitiert auf den Seiten 2 and 3.)
- [18] W. Suttor, M. Johler, D. Weisenberger, Das Mini-Blockheizkraftwerk: eine Heizung, die auch Strom erzeugt; mit neuen Gesetzen und Fördermaßnahmen ab 1.1. 2009, CF Müller, 2009. (Zitiert auf den Seiten 8, 9 and 33.)
- [19] Z. Hu, J.-h. Kim, J. Wang, J. Byrne, Review of dynamic pricing programs in the us and europe: Status quo and policy recommendations, Renewable and Sustainable Energy Reviews 42 (2015) 743–751. (Zitiert auf Seite 8.)

- [20] J. Stromback, C. Dromacque, M. H. Yassin, The potential of smart meter enabled programs to increase energy and systems efficiency: a mass pilot comparison short name: Empower demand, Vaasa ETT, Global Energy Think Tank. (Zitiert auf Seite 8.)
- [21] M. Pehnt, M. Cames, C. Fischer, B. Praetorius, L. Schneider, K. Schumacher, J.-P. Voß, Micro cogeneration: towards decentralized energy systems, Springer Science & Business Media, 2006. (Zitiert auf Seite 9.)
- [22] O. A. Shaneb, P. C. Taylor, Evaluation of alternative operating strategies for residential micro combined heat and power, in: Energy Conference and Exhibition (EnergyCon), 2010 IEEE International, IEEE, 2010, pp. 143–148. (Zitiert auf Seite 9.)
- [23] E. S. Barbieri, F. Melino, M. Morini, Influence of the thermal energy storage on the profitability of micro-chp systems for residential building applications, *Applied Energy* 97 (2012) 714–722. (Zitiert auf Seite 10.)
- [24] E. S. Barbieri, P. R. Spina, M. Venturini, Analysis of innovative micro-chp systems to meet household energy demands, *Applied Energy* 97 (2012) 723–733. (Zitiert auf Seite 10.)
- [25] L. Mongibello, N. Bianco, M. Caliano, G. Graditi, Influence of heat dumping on the operation of residential micro-chp systems, *Applied Energy* 160 (2015) 206–220. (Zitiert auf Seite 10.)
- [26] M. Houwing, R. R. Negenborn, B. De Schutter, Demand response with micro-chp systems, *Proceedings of the IEEE* 99 (1) (2011) 200–213. (Zitiert auf Seite 10.)
- [27] S. Sudtharalingam, A. Hawkes, T. Green, Feasibility of domestic micro combined heat and power units with real time pricing, in: IEEE PES General Meeting, IEEE, 2010, pp. 1–8. (Zitiert auf Seite 10.)
- [28] K. Zhou, J. Pan, L. Cai, Optimal combined heat and power system scheduling in smart grid, in: IEEE INFOCOM 2014-IEEE Conference on Computer Communications, IEEE, 2014, pp. 2831–2839. (Zitiert auf Seite 10.)
- [29] G. Díaz, B. Moreno, Valuation under uncertain energy prices and load demands of micro-chp plants supplemented by optimally switched thermal energy storage, *Applied Energy* 177 (2016) 553–569. (Zitiert auf Seite 10.)
- [30] A. Alahäivälä, T. Heß, S. Cao, M. Lehtonen, Analyzing the optimal coordination of a residential micro-chp system with a power sink, *Applied Energy* 149 (2015) 326–337. (Zitiert auf Seite 10.)
- [31] M. Bianchi, A. De Pascale, F. Melino, Performance analysis of an integrated chp system with thermal and electric energy storage for residential application, *Applied Energy* 112 (2013) 928–938. (Zitiert auf Seite 10.)

- [32] V. Antonucci, L. Branchini, G. Brunaccini, A. D. Pascale, M. Ferraro, F. Melino, V. Orlandini, F. Sergi, Thermal integration of a SOFC power generator and a Na–NiCl₂ battery for CHP domestic application, *Applied Energy*. (Zitiert auf den Seiten 10 and 11.)
- [33] P. Balcombe, D. Rigby, A. Azapagic, Energy self-sufficiency, grid demand variability and consumer costs: Integrating solar pv, stirling engine chp and battery storage, *Applied Energy* 155 (2015) 393–408. (Zitiert auf Seite 11.)
- [34] C. Change, The scientific basis. intergovernmental panel on climate change, by JT Houghton, Y. Ding, DJ Griggs, et al. (Zitiert auf Seite 15.)
- [35] H.-J. Wagner, M. K. Koch, J. Burkhardt, T. G. Bockmann, N. Feck, P. Kruse, Co₂-emissionen der stromerzeugung – ein ganzheitlicher vergleich verschiedener techniken, *BWK-Das Energie Fachmagazin* 59 (10) (2007) 44–52. (Zitiert auf Seite 15.)
- [36] P. Icha, Entwicklung der spezifischen Kohlendioxid-Emissionen des deutschen Strommix in den Jahren 1990 bis 2012, Umweltbundesamt, 2013. (Zitiert auf Seite 15.)
- [37] P. Icha, Entwicklung der spezifischen Kohlendioxid-Emissionen des deutschen Strommix in den Jahren 1990 bis 2015, Umweltbundesamt, 2016. (Zitiert auf den Seiten 15, 16, 60 and 68.)
- [38] Eurostat, the Statistical Office of the European Union, Electricity prices for domestic consumers, http://ec.europa.eu/eurostat/statistics-explained/index.php/Energy_price_statistics, letzter Zugriff am 01.08.2016. (Zitiert auf den Seiten 17 and 31.)
- [39] Eurostat, the Statistical Office of the European Union, Natural gas price statistics, http://ec.europa.eu/eurostat/statistics-explained/index.php/Natural_gas_price_statistics#Natural_gas_prices_for_household_consumers, letzter Zugriff am 25.07.2016. (Zitiert auf den Seiten 17 and 31.)
- [40] P. Ren, Renewables 2015 global status report, REN21 Secretariat: Paris, France. (Zitiert auf Seite 17.)
- [41] K. Solangi, M. Islam, R. Saidur, N. Rahim, H. Fayaz, A review on global solar energy policy, *Renewable and sustainable energy reviews* Volume 15 (2011) 2149–2163. (Zitiert auf Seite 17.)
- [42] P. Mir-Artigues, E. Cerdá, P. del Río, Analyzing the impact of cost-containment mechanisms on the profitability of solar pv plants in Spain, *Renewable and Sustainable Energy Reviews* Volume 46 (2015) 166–177. (Zitiert auf Seite 18.)

- [43] BDEW Bundesverband der Energie- und Wasserwirtschaft e.V., Stromverbrauch im Haushalt (2013) p.10. (Zitiert auf Seite 28.)
- [44] NEW Netz GmbH, Lastprofil im Haushalt 10, <https://www.new-netz-gmbh.de/energie-marktpartner/veroeffentlichungspflichten/stromnzv/standardlastprofile/>, letzter Zugriff am 08.06.2016. (Zitiert auf den Seiten 28 and 126.)
- [45] D_ STATIS Statistisches Bundesamt, Durchschnittliche Wohnfläche pro Person nach Haushaltstyp, https://www.destatis.de/DE/Methoden/Zensus_/Tabellen/Wohnsituation_HH_Zensus11_Wohnflaeche.html, letzter Zugriff am 08.06.2016 (2011). (Zitiert auf Seite 28.)
- [46] Verein Deutscher Ingenieure, Economic efficiency of building installations: Fundamentals and economic calculation, vdi 2067 part 1. (Zitiert auf Seite 28.)
- [47] Bundesamt für Wirtschaft und Ausfuhrkontrolle, Wärme und Kälte-speicher, http://www.bafa.de/bafa/de/energie/kraft_waerme_kopplung/waerme_und_kaeltespeicher/index.html, zugriff am 12.09.2016. (Zitiert auf Seite 30.)
- [48] D. Murray, J. Liao, L. Stankovic, V. Stankovic, R. Hauxwell-Baldwin, C. Wilson, M. Coleman, T. Kane, S. Firth, A data management platform for personalised real-time energy feedback, 2015. (Zitiert auf den Seiten 30, 51, 66, 101 and 104.)
- [49] G. Orr, T. Dennish, I. Summerfield, F. Purcell, Commercial micro-chp field trial report, Report of Sustainable Energy Authority of Ireland (SEAI). (Zitiert auf den Seiten 34 and 40.)
- [50] M. Gailfuß, BHKW – Grundlagen der KWK Planung, <https://www.bhkw-infozentrum.de/allgemeine-erlaeuterungen-bhkw-kwk/planung-kwk.html>, letzter Zugriff am 04.02.2016. (Zitiert auf Seite 34.)
- [51] C. Gerwig, Short term load forecasting for residential buildings—an extensive literature review, in: Intelligent Decision Technologies, Springer, 2015, pp. 181–193. (Zitiert auf den Seiten 34 and 82.)
- [52] J. Hosking, R. Natarajan, S. Ghosh, S. Subramanian, X. Zhang, Short-term forecasting of the daily load curve for residential electricity usage in the smart grid, Applied Stochastic Models in Business and Industry 29 (6) (2013) 604–620. (Zitiert auf den Seiten 35, 95 and 99.)
- [53] R. Perez, S. Kivalov, J. Schlemmer, K. Hemker, D. Renné, T. E. Hoff, Validation of short and medium term operational solar radiation forecasts in the us, Solar Energy 84 (12) (2010) 2161–2172. (Zitiert auf Seite 35.)

- [54] D. Fischer, T. Wolf, J. Scherer, B. Wille-Haussmann, A stochastic bottom-up model for space heating and domestic hot water load profiles for german households, *Energy and Buildings* 124 (2016) 120–128. (Zitiert auf Seite 35.)
- [55] D. Nestle, J. Ringelstein, H. Waldschmidt, Open Energy Gateway Architecture for Customers in the Distribution – GridArchitektur eines offenen Gateways für Energiemanagement und Energieeffizienz für Verteilnetzkunden, *IT-Information Technology Methoden und innovative Anwendungen der Informatik und Informationstechnik* 52 (2) (2010) 83–88. (Zitiert auf Seite 46.)
- [56] C. W. Gellings, The concept of demand-side management for electric utilities, *Proceedings of the IEEE* 73 (10) (1985) 1468–1470. (Zitiert auf Seite 50.)
- [57] Presse- und Informationsamt der Bundesregierung, Leitmarkt und Leitanbieter für Elektromobilität, http://www.bundesregierung.de/Webs/Breg/DE/Themen/Energiewende/Mobilitaet/podcast/_node.html, letzter Zugriff am 17.04.2015. (Zitiert auf Seite 50.)
- [58] D. Behrens, C. Gerwig, Selbstregulierende Verbraucher im Smart Grid: Design einer Infrastruktur mit Hilfe eines Multi-Agenten-Systems, in: *Multikonferenz Wirtschaftsinformatik*, 2014, pp. 935–948. (Zitiert auf Seite 51.)
- [59] C. Gerwig, D. Behrens, H. Lessing, R. Knackstedt, Demand side management in residential contexts-a literature review., in: *GI-Jahrestagung*, 2015, pp. 93–107. (Zitiert auf den Seiten 51, 52 and 53.)
- [60] S. Ali, S. Maqbool, T. I. Ahamed, N. Malik, Pursuit algorithm for optimized load scheduling, in: *Power Engineering and Optimization Conference (PEOCO)* Melaka, Malaysia, 2012 Ieee International, IEEE, 2012, pp. 193–198. (Zitiert auf den Seiten 52 and 53.)
- [61] G.-R. Liu, P. Lin, Y. Fang, Y.-B. Lin, Optimal threshold policy for in-home smart grid with renewable generation integration, *IEEE Transactions on Parallel and Distributed Systems* 26 (4) (2015) 1096–1105. (Zitiert auf den Seiten 52 and 53.)
- [62] J. Lee, G.-L. Park, Power load distribution for wireless sensor and actuator networks in smart grid buildings, *international Journal of Distributed sensor Networks* 2013. (Zitiert auf den Seiten 52 and 53.)
- [63] K. Mets, T. Verschueren, W. Haerick, C. Develder, F. De Turck, Optimizing smart energy control strategies for plug-in hybrid electric vehicle charging, in: *Network Operations and Management Symposium Workshops (NOMS Wksp)*, 2010 IEEE/IFIP, Ieee, 2010, pp. 293–299. (Zitiert auf Seite 52.)
- [64] S. Ali, S. Maqbool, T. I. Ahamed, N. Malik, Load scheduling with maximum demand and time of use pricing for microgrids, in: *Global Humanitarian*

- Technology Conference: South Asia Satellite (GHTC-SAS), 2013 IEEE, IEEE, 2013, pp. 234–238. (Zitiert auf Seite 52.)
- [65] J. Lee, G.-L. Park, H.-J. Kim, Multithreaded power consumption scheduler based on a genetic algorithm, in: *Communication and Networking*, Springer, 2011, pp. 47–52. (Zitiert auf Seite 52.)
- [66] L. Jia, Z. Yu, M. C. Murphy-Hoye, A. Pratt, E. G. Piccioli, L. Tong, Multi-scale stochastic optimization for home energy management, in: *Computational Advances in Multi-Sensor Adaptive Processing (CAMSAP)*, 2011 4th IEEE International Workshop on, IEEE, 2011, pp. 113–116. (Zitiert auf den Seiten 52, 53 and 79.)
- [67] R. Pereira, A. Fagundes, R. Melício, V. M. Mendes, J. Figueiredo, J. Martins, J. Quadrado, Demand response analysis in smart grids using fuzzy clustering model, in: *Doctoral Conference on Computing, Electrical and Industrial Systems*, Springer, 2013, pp. 403–412. (Zitiert auf den Seiten 52 and 79.)
- [68] S. Marco, S. Squartini, G. P. Surace, F. Piazza, Smart home task and energy resource scheduling based on nonlinear programming, in: *Recent Advances of Neural Network Models and Applications*, Springer, 2014, pp. 175–185. (Zitiert auf den Seiten 52, 53 and 79.)
- [69] D. Atabay, S. Herzog, F. Sängler, J. Jungwirth, V. Mikulovic, Self-adapting building models and optimized hvac scheduling for demand side management, in: *Electricity Distribution (CIRED 2013)*, 22nd International Conference and Exhibition on, IET, 2013, pp. 1–4. (Zitiert auf den Seiten 52 and 79.)
- [70] R. Missaoui, G. Warkozek, S. Bacha, S. Ploix, Energy fluxes optimization for pv integrated building, in: *PowerTech*, 2011 IEEE Trondheim, IEEE, 2011, pp. 1–7. (Zitiert auf den Seiten 52 and 79.)
- [71] F. De Angelis, M. Boaro, D. Fuselli, S. Squartini, F. Piazza, Q. Wei, D. Wang, Optimal task and energy scheduling in dynamic residential scenarios, in: *International Symposium on Neural Networks*, Springer, 2012, pp. 650–658. (Zitiert auf Seite 52.)
- [72] N. Bassamzadeh, R. Ghanem, S. Lu, S. J. Kazemitabar, Robust scheduling of smart appliances with uncertain electricity prices in a heterogeneous population, *Energy and Buildings* 84 (2014) 537–547. (Zitiert auf den Seiten 52 and 53.)
- [73] S.-J. Kim, G. B. Giannakis, Efficient and scalable demand response for the smart power grid, in: *Computational Advances in Multi-Sensor Adaptive Processing (CAMSAP)*, 2011 4th IEEE International Workshop on, IEEE, 2011, pp. 109–112. (Zitiert auf Seite 52.)

- [74] H. Miao, X. Huang, G. Chen, A genetic evolutionary task scheduling method for energy efficiency in smart homes, *International Journal of Electrical Engineering* 7 (5) (2012) 1827. (Zitiert auf Seite 52.)
- [75] S. Maqbool, T. I. Ahamed, S. Ali, F. Pazheri, N. Malik, Comparison of pursuit and ε -greedy algorithm for load scheduling under real time pricing, in: *Power and Energy (PECon), 2012 IEEE International Conference on*, IEEE, 2012, pp. 515–519. (Zitiert auf den Seiten 52 and 53.)
- [76] H. Bu, K. Nygard, Adaptive scheduling of smart home appliances using fuzzy goal programming, in: *The Sixth International Conference on Adaptive and Self-Adaptive Systems and Applications, ADAPTIVE*, Citeseer, 2014, pp. 129–135. (Zitiert auf Seite 52.)
- [77] M. R. Alam, M. St-Hilaire, T. Kunz, Cost optimization via rescheduling in smart grids—a linear programming approach, in: *Smart Energy Grid Engineering (SEGE), 2013 IEEE International Conference on*, IEEE, 2013, pp. 1–6. (Zitiert auf Seite 52.)
- [78] T. Hu, X. Chu, W. Zhang, Y. Liu, An optimal day-ahead dispatch strategy for deferrable loads, in: *Power System Technology (POWERCON), 2014 International Conference on*, IEEE, 2014, pp. 1785–1790. (Zitiert auf Seite 52.)
- [79] Y. Liang, R. Zou, S. A. Wang, M. Zhou, Auto-dr optimal decision-making method of smart home based on rtp, in: *Applied Mechanics and Materials*, Vol. 602, Trans Tech Publ, 2014, pp. 3817–3821. (Zitiert auf Seite 52.)
- [80] M. Castillo-Cagigal, A. Gutiérrez, F. Monasterio-Huelin, E. Caamaño-Martín, D. Masa, J. Jiménez-Leube, A semi-distributed electric demand-side management system with pv generation for self-consumption enhancement, *Energy Conversion and Management* 52 (7) (2011) 2659–2666. (Zitiert auf den Seiten 52 and 53.)
- [81] A. Ranjini, B. Zoraida, Preemptive appliances scheduling in smart home using genetic algorithm, in: *Artificial Intelligence and Evolutionary Algorithms in Engineering Systems*, Springer, 2015, pp. 387–393. (Zitiert auf Seite 52.)
- [82] EnergieAgentur, NRW, Erhebung „Wo im Haushalt bleibt der Strom?“. (Zitiert auf den Seiten 52 and 79.)
- [83] H. H. Chen, R. H. Louie, Y. Li, P. Wang, B. Vucetic, A variational inequality approach to instantaneous load pricing based demand side management for future smart grid, in: *2013 IEEE International Conference on Communications (ICC)*, IEEE, 2013, pp. 4250–4254. (Zitiert auf Seite 54.)
- [84] O. Beaude, S. Lasaulce, M. Hennebel, Charging games in networks of electrical vehicles, in: *Network Games, Control and Optimization (NetGCooP), 2012 6th International Conference on*, IEEE, 2012, pp. 96–103. (Zitiert auf Seite 54.)

- [85] P. Samadi, A.-H. Mohsenian-Rad, R. Schober, V. W. Wong, J. Jatskevich, Optimal real-time pricing algorithm based on utility maximization for smart grid, in: Smart Grid Communications (SmartGridComm), 2010 First IEEE International Conference on, IEEE, 2010, pp. 415–420. (Zitiert auf den Seiten 54, 55 and 56.)
- [86] E. Manasseh, S. Ohno, A. Mvuma, T. Yamamoto, Distributed demand-side management with load uncertainty, in: ITU Kaleidoscope Academic Conference: Living in a converged world-Impossible without standards?, Proceedings of the 2014, IEEE, 2014, pp. 23–28. (Zitiert auf den Seiten 54 and 55.)
- [87] H. M. Soliman, A. Leon-Garcia, Game-theoretic demand-side management with storage devices for the future smart grid, IEEE Transactions on Smart Grid 5 (3) (2014) 1475–1485. (Zitiert auf den Seiten 54 and 55.)
- [88] M. Fathi, M. Gholami, Localized demand-side management in electric power systems, in: Smart Grids (ICSG), 2012 2nd Iranian Conference on, IEEE, 2012, pp. 1–4. (Zitiert auf den Seiten 54 and 55.)
- [89] P. Chavali, P. Yang, A. Nehorai, A distributed algorithm of appliance scheduling for home energy management system, IEEE Transactions on Smart Grid 5 (1) (2014) 282–290. (Zitiert auf Seite 54.)
- [90] P. Mc Namara, S. McLoone, Hierarchical demand response using dantzig-wolfe decomposition, in: IEEE PES ISGT Europe 2013, IEEE, 2013, pp. 1–5. (Zitiert auf Seite 54.)
- [91] I. Dusparic, C. Harris, A. Marinescu, V. Cahill, S. Clarke, Multi-agent residential demand response based on load forecasting, in: Technologies for Sustainability (SusTech), 2013 1st IEEE Conference on, IEEE, 2013, pp. 90–96. (Zitiert auf Seite 55.)
- [92] Y. Huang, S. Mao, R. Nelms, Smooth electric power scheduling in power distribution networks, in: 2012 IEEE Globecom Workshops, IEEE, 2012, pp. 1469–1473. (Zitiert auf Seite 55.)
- [93] R. Verschae, H. Kawashima, T. Kato, T. Matsuyama, A distributed coordination framework for on-line scheduling and power demand balancing of households communities, in: Control Conference (ECC), 2014 European, IEEE, 2014, pp. 1655–1662. (Zitiert auf Seite 55.)
- [94] E. L. Quinn, Privacy and the new energy infrastructure, Available at SSRN 1370731. (Zitiert auf Seite 56.)
- [95] Y. Yuan, Z. Li, K. Ren, Modeling load redistribution attacks in power systems, IEEE Transactions on Smart Grid 2 (2) (2011) 382–390. (Zitiert auf Seite 56.)

- [96] Bundesministerium für Wirtschaft und Energie(BMWi), Smart Energy made in Germany. Erkenntnisse zum Aufbau und zur Nutzung intelligenter Energiesysteme im Rahmen der Energiewende, Selbstverlag, 2014. (Zitiert auf Seite 56.)
- [97] M. Laskowski, et al., Konsortial-Abschlussbericht Verbundprojekt E-Energy: E-DeMa, Entwicklung und Demonstration dezentral vernetzter Energiesysteme hin zum E-Energy-Marktplatz der Zukunft (2013). (Zitiert auf Seite 57.)
- [98] R. Paschotta, Artikel 'Stromtarif' im RP-Energie-Lexikon, <https://www.energie-lexikon.info/stromtarif.html>, letzter Zugriff am 06.01.2017. (Zitiert auf Seite 77.)
- [99] T. Weichert, Stellungnahme des Unabhängigen Landeszentrums für Datenschutz Schleswig-Holstein (ULD) vom 10.06.2011 zum Gesetzentwurf der Bundesregierung eines Gesetzes zur Neuordnung energiewirtschaftlicher Vorschriften (BR-Drs. 343/11), <https://www.datenschutzzentrum.de/smartmeter/20110615-smartmeterregelung.htm>, letzter Zugriff am 25.01.2017 (2011). (Zitiert auf Seite 78.)
- [100] A. Barbato, A. Capone, Optimization models and methods for demand-side management of residential users: A survey, *Energies* 7 (9) (2014) 5787–5824. (Zitiert auf Seite 79.)
- [101] D. W. Bunn, Short-term forecasting: A review of procedures in the electricity supply industry, *The Journal of the Operational Research Society* 33 (6) (1982) 533–545. (Zitiert auf den Seiten 82 and 83.)
- [102] C. Gerwig, Short term load forecasting for residential buildings — an evaluation based on publicly available datasets., in: 1st EAI International Conference on Smart Grid Inspired Future Technologies, Proceedings, 2016. (Zitiert auf den Seiten 83, 107 and 113.)
- [103] H. K. Alfares, M. Nazeeruddin, Electric load forecasting: literature survey and classification of methods, *International Journal of Systems Science* 33 (1) (2002) 23–34. (Zitiert auf Seite 83.)
- [104] L. Suganthi, A. A. Samuel, Energy models for demand forecasting—a review, *Renewable and sustainable energy reviews* 16 (2) (2012) 1223–1240. (Zitiert auf Seite 83.)
- [105] J.-P. Kreiß, G. Neuhaus, Einführung in die Zeitreihenanalyse, Springer-Verlag, 2006. (Zitiert auf den Seiten 88, 89 and 90.)
- [106] G. E. Box, G. M. Jenkins, G. C. Reinsel, G. M. Ljung, Time series analysis: forecasting and control, John Wiley & Sons, 2015. (Zitiert auf Seite 89.)

- [107] M. Rossi, D. Brunelli, Electricity demand forecasting of single residential units, in: Environmental Energy and Structural Monitoring Systems (EESMS), 2013 IEEE Workshop on, IEEE, 2013, pp. 1–6. (Zitiert auf den Seiten 89, 95, 96, 97, 98 and 99.)
- [108] G. Cybenko, Approximation by superpositions of a sigmoidal function, Mathematics of control, signals and systems 2 (4) (1989) 303–314. (Zitiert auf Seite 92.)
- [109] C. Cortes, V. Vapnik, Support-vector networks, Machine learning 20 (3) (1995) 273–297. (Zitiert auf Seite 93.)
- [110] E. Alpaydin, S. Linke, Maschinelles lernen, Oldenbuourg Wissenschaftsverlag, München. (Zitiert auf den Seiten 93, 112 and 113.)
- [111] V. Vapnik, The nature of statistical learning theory, Springer Science & Business Media, 2013. (Zitiert auf Seite 93.)
- [112] A. Veit, C. Goebel, R. Tidke, C. Doblander, H.-A. Jacobsen, Household electricity demand forecasting: benchmarking state-of-the-art methods, in: Proceedings of the 5th international conference on Future energy systems, ACM, 2014, pp. 233–234. (Zitiert auf den Seiten 95, 96, 97, 98, 99, 102, 106, 107 and 112.)
- [113] C. Bennett, R. A. Stewart, J. Lu, Autoregressive with exogenous variables and neural network short-term load forecast models for residential low voltage distribution networks, Energies 7 (5) (2014) 2938–2960. (Zitiert auf den Seiten 95, 96, 98, 107 and 133.)
- [114] M. Chaouch, Clustering-based improvement of nonparametric functional time series forecasting: Application to intra-day household-level load curves, IEEE Transactions on Smart Grid 5 (1) (2014) 411–419. (Zitiert auf den Seiten 95, 97, 102 and 113.)
- [115] Y. Fujimoto, Y. Hayashi, Pattern sequence-based energy demand forecast using photovoltaic energy records, in: Renewable Energy Research and Applications (ICRERA), 2012 International Conference on, IEEE, 2012, pp. 1–6. (Zitiert auf den Seiten 95 and 113.)
- [116] M. Ghofrani, M. Hassanzadeh, M. Etezadi-Amoli, M. Fadali, Smart meter based short-term load forecasting for residential customers, in: North American Power Symposium (NAPS), 2011, IEEE, 2011, pp. 1–5. (Zitiert auf den Seiten 95 and 99.)
- [117] S. Humeau, T. K. Wijaya, M. Vasirani, K. Aberer, Electricity load forecasting for residential customers: Exploiting aggregation and correlation between households, in: Sustainable Internet and ICT for Sustainability (SustainIT), 2013, IEEE, 2013, pp. 1–6. (Zitiert auf den Seiten 95, 97, 98, 99, 102 and 112.)

- [118] Y. Iwafune, Y. Yagita, T. Ikegami, K. Ogimoto, Short-term forecasting of residential building load for distributed energy management, in: Energy Conference (ENERGYCON), 2014 IEEE International, IEEE, 2014, pp. 1197–1204. (Zitiert auf Seite 95.)
- [119] F. Javed, N. Arshad, F. Wallin, I. Vassileva, E. Dahlquist, Forecasting for demand response in smart grids: An analysis on use of anthropologic and structural data and short term multiple loads forecasting, *Applied Energy* 96 (2012) 150–160. (Zitiert auf den Seiten 95 and 96.)
- [120] A. Marinescu, I. Dusparic, C. Harris, V. Cahill, S. Clarke, A dynamic forecasting method for small scale residential electrical demand, in: 2014 International Joint Conference on Neural Networks (IJCNN), IEEE, 2014, pp. 3767–3774. (Zitiert auf den Seiten 95, 97 and 99.)
- [121] A. Mutanen, S. Repo, P. Järventausta, Customer classification and load profiling based on amr measurements, in: Proceedings of the 21st International Conference on Electricity Distribution (CIRED 2011), Frankfurt, Germany, paper, Vol. 277, 2010. (Zitiert auf Seite 95.)
- [122] T. Qingfeng, Z. Jianhua, X. Zhengyong, Short-term micro-grid load forecast method based on emd-kelm-ekf, in: Intelligent Green Building and Smart Grid (IGBSG), 2014 International Conference on, IEEE, 2014, pp. 1–4. (Zitiert auf Seite 95.)
- [123] R. Sevlian, R. Rajagopal, Short term electricity load forecasting on varying levels of aggregation, arXiv preprint arXiv:1404.0058. (Zitiert auf den Seiten 95, 96, 97, 98, 107, 109 and 129.)
- [124] A. Tidemann, H. Langseth, P. Öztürk, et al., Effects of scale on load prediction algorithms, in: Electricity Distribution (CIRED 2013), 22nd International Conference and Exhibition on, IET, 2013, pp. 1–4. (Zitiert auf den Seiten 95, 96, 97, 98, 99 and 107.)
- [125] T. K. Wijaya, S. Humeau, M. Vasirani, K. Aberer, Residential electricity load forecasting: evaluation of individual and aggregate forecasts, Tech. rep., Technical report (2014). (Zitiert auf den Seiten 95, 96, 97, 98, 99 and 102.)
- [126] H.-T. Yang, J.-T. Liao, C.-I. Lin, A load forecasting method for hems applications, in: PowerTech (POWERTECH), 2013 IEEE Grenoble, IEEE, 2013, pp. 1–6. (Zitiert auf den Seiten 95, 98, 99 and 112.)
- [127] J. Yoo, B. Park, K. An, E. A. Al-Ammar, Y. Khan, K. Hur, J. H. Kim, Look-ahead energy management of a grid-connected residential pv system with energy storage under time-based rate programs, *Energies* 5 (4) (2012) 1116–1134. (Zitiert auf Seite 95.)

- [128] J. Z. Kolter, M. J. Johnson, Redd: A public data set for energy disaggregation research, in: Workshop on Data Mining Applications in Sustainability (SIGKDD), San Diego, CA, 2011. (Zitiert auf den Seiten 97 and 101.)
- [129] K. Neusser, Zeitreihenanalyse in den Wirtschaftswissenschaften, Springer, 2011. (Zitiert auf Seite 107.)
- [130] D. A. Dickey, W. R. Bell, R. B. Miller, Unit roots in time series models: Tests and implications, *The American Statistician* 40 (1) (1986) 12–26. (Zitiert auf Seite 110.)
- [131] T. Schaul, J. Bayer, D. Wierstra, Y. Sun, M. Felder, F. Sehnke, T. Rückstieß, J. Schmidhuber, PyBrain, *Journal of Machine Learning Research* 11 (2010) 743–746. (Zitiert auf Seite 112.)
- [132] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, J. Vanderplas, A. Passos, D. Cournapeau, M. Brucher, M. Perrot, E. Duchesnay, Scikit-learn: Machine learning in Python, *Journal of Machine Learning Research* 12 (2011) 2825–2830. (Zitiert auf Seite 113.)
- [133] L. Hyafil, R. L. Rivest, Constructing optimal binary decision trees is np-complete, *Information Processing Letters* 5 (1) (1976) 15–17. (Zitiert auf Seite 115.)
- [134] D. Koch, Verbesserung von Klassifikationsverfahren: Informationsgehalt der k-Nächsten-Nachbarn nutzen, Springer-Verlag, 2015. (Zitiert auf Seite 116.)
- [135] L. Fahrmeir, T. Kneib, S. Lang, Regression: Modelle, Methoden und Anwendungen, Springer-Verlag, 2009. (Zitiert auf Seite 127.)
- [136] O. Parson, Unsupervised training methods for non-intrusive appliance load monitoring from smart meter data, Ph.D. thesis, University of Southampton (2014). (Zitiert auf Seite 134.)
- [137] Z. Guo, Z. J. Wang, A. Kashani, Home appliance load modeling from aggregated smart meter data, *IEEE Transactions on Power Systems* 30 (1) (2015) 254–262. (Zitiert auf Seite 134.)
- [138] J. Liao, G. Elafoudi, L. Stankovic, V. Stankovic, Non-intrusive appliance load monitoring using low-resolution smart meter data, in: Smart Grid Communications (SmartGridComm), 2014 IEEE International Conference on, IEEE, 2014, pp. 535–540. (Zitiert auf Seite 134.)
- [139] EEBus Initiative e.V, Non-profit organization for interoperability, <https://www.eebus.org/ueber-uns/>, letzter Zugriff am 27.01.2017. (Zitiert auf Seite 141.)

-
- [140] R. Höfer-Zygan, E. Oswald, M. Heidrich, Smart Grid Communication 2020: Fokus Deutschland, Fraunhofer-Einrichtung für Systeme der Kommunikationstechnik ESK, https://www.esk.fraunhofer.de/content/dam/esk/dokumente/SmartGrid_Studie_dt_web_neu.pdf, letzter Zugriff am 27.01.2017 (2011). (Zitiert auf Seite 141.)
- [141] Gaßner, Groth, Siederer & Coll.: Energie-Newsletter 2014, Kammergericht bestätigt [GGSC] zur Kundenanlage, <http://www.ggsc.de/aktuelles/aktuelle-newsletter/newsletter-artikel/news/355-kammergericht-bestaetigt-ggsc-zur-kundenanlage/>, letzter Zugriff am 27.01.2017. (Zitiert auf Seite 141.)
- [142] H.-P. Ahmels, et al., Erneuerbare Energien statt Atomenergie, EUROSOLAR-Aufruf (2004), http://www.hermannscheer.de/de/images/stories/pdf/Kampagne_Erneuerbare_statt_Atomkraft_sep04.pdf, letzter Zugriff am 25.01.2017. (Zitiert auf Seite 141.)
- [143] J. G. MacKinnon, Critical values for cointegration tests, Tech. rep., Queen's Economics Department Working Paper (2010). (Zitiert auf Seite 145.)
- [144] J. G. MacKinnon, Approximate asymptotic distribution functions for unit-root and cointegration tests, *Journal of Business & Economic Statistics* 12 (2) (1994) 167–176. (Zitiert auf Seite 142.)
- [145] S. Seabold, J. Perktold, Statsmodels: Econometric and statistical modeling with python, in: 9th Python in Science Conference, 2010. (Zitiert auf Seite 142.)